



Programa de Pós-Graduação em

Computação Aplicada

Doutorado Acadêmico

Paulo César Büttendender

Eigenroutines: Modelo computacional para identificação de padrões comportamentais em pessoas com transtornos neuropsiquiátricos utilizando históricos de contextos

São Leopoldo, 2020

UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO
EM COMPUTAÇÃO APLICADA
NÍVEL DOUTORADO

PAULO CÉSAR BÜTTENBENDER

**EIGENROUTINES:
MODELO COMPUTACIONAL PARA IDENTIFICAÇÃO DE PADRÕES
COMPORTAMENTAIS EM PESSOAS COM TRANSTORNOS
NEUROPSIQUIÁTRICOS UTILIZANDO HISTÓRICOS DE CONTEXTOS**

São Leopoldo
2020

Paulo César Büttendender

EIGENROUTINES:

**MODELO COMPUTACIONAL PARA IDENTIFICAÇÃO DE PADRÕES
COMPORTAMENTAIS EM PESSOAS COM TRANSTORNOS
NEUROPSIQUIÁTRICOS UTILIZANDO HISTÓRICOS DE CONTEXTOS**

Tese apresentada como requisito parcial para a
obtenção do título de Doutor, pelo Programa de
Pós-Graduação em Computação Aplicada da
Universidade do Vale do Rio dos Sinos –
UNISINOS

Orientador: Dr. Jorge Luis Victória Barbosa

São Leopoldo

2020

B928e Büttenbender, Paulo César.
Eigenroutines: modelo computacional para identificação de padrões comportamentais em pessoas com transtornos neuropsiquiátricos utilizando histórico de contextos / Paulo César Büttenbender. – 2020.
116 f. : il. color. ; 30 cm.

Tese (doutorado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, São Leopoldo, 2020.

“Orientador: Dr. Jorge Luis Victória Barbosa.”

1. Computação ubíqua. 2. Sensibilidade de contextos. 3. Histórico de contextos. 4. Análise de similaridade. I. Título.

CDU 004.5

Dados Internacionais de Catalogação na Publicação (CIP)

(Bibliotecária: Bruna Sant’Anna – CRB 10/2360)

*À minha esposa Mirian,
pela paciência,
pelo carinho,
pelas revisões,
e pelos incontáveis cafés e energéticos.*

AGRADECIMENTOS

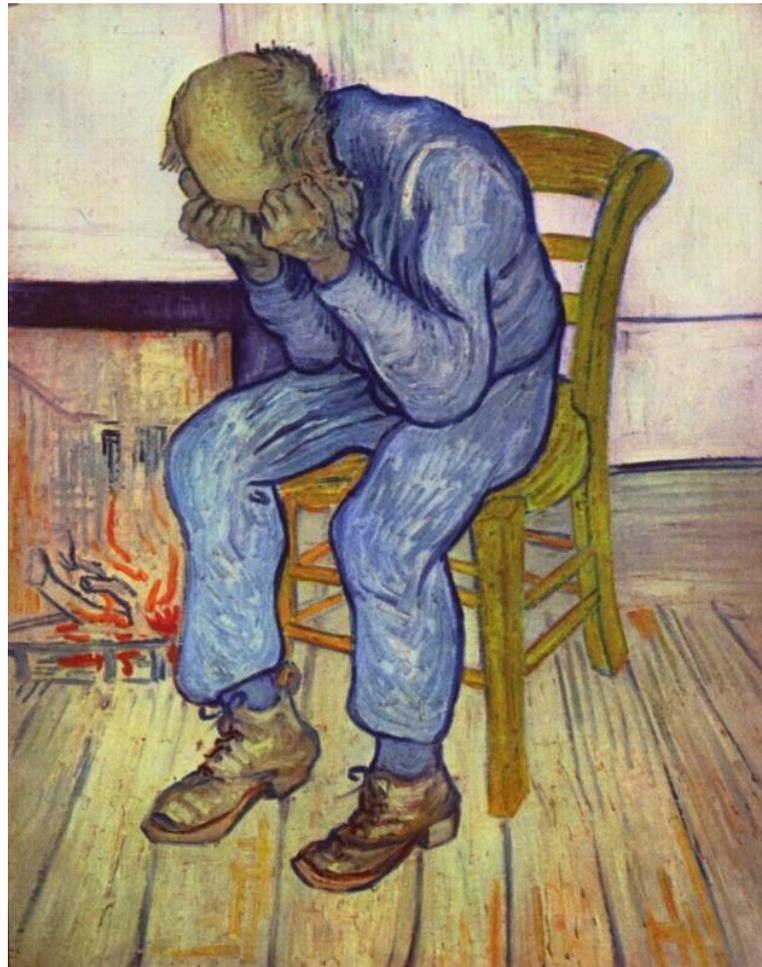
Agradeço principalmente a meu orientador prof. Dr. Jorge Luis Victória Barbosa, cujo empenho, dedicação e motivação eu nunca vi igual, este trabalho definitivamente não seria possível sem todo seu empenho e apoio.

Aos colegas do laboratório de computação ubíqua aplicada a saúde: Henrique, Lucas e Rodrigo. Podem não ter percebido mas a troca de ideias e interação foi fundamental.

A todos os demais colegas que direta ou indiretamente contribuíram com ideias e ferramentas para auxiliar no andamento deste trabalho, meu muito obrigado.

“Though I am often in the depths of misery, there is still calmness, pure harmony and music inside me. I see paintings or drawings in the poorest cottages, in the dirtiest corners. And my mind is driven towards these things with an irresistible momentum.”

— Vincent van Gogh



At Eternity's Gate, 1890. Fonte: (WIKIMEDIA, 2020)

Vincent Van Gogh pintou esta obra durante um período de relapso de transtorno bipolar, e completou dois meses antes de cometer suicídio.

Esta obra de domínio público está disponível para visitaç o no museu Kr ller-M ller em Otterlo na Holanda.

RESUMO

Por muito tempo os transtornos neuropsiquiátricos foram negligenciados pelos órgãos de saúde pública, em grande parte devido a baixa mortalidade diretamente atribuída aos mesmos. O pouco interesse refletiu em baixo investimento em pesquisa e em práticas médicas, e como consequência transtornos neuropsiquiátricos estão hoje entre as doenças com maior impacto socioeconômico. Considerando que parte destes transtornos são passíveis de diagnóstico por alterações no comportamento rotineiro do paciente e que smartphones e *wearables* estão cada vez mais presentes na sociedade, é natural imaginar que o uso destes dispositivos possa auxiliar nos diagnósticos, nos tratamentos e num melhor entendimento destes transtornos e como eles afetam a população, através de perfis epidemiológicos.

A computação ubíqua, mais precisamente na aplicação e uso de históricos de contextos é uma forma de aplicação de recursos computacionais que utiliza os sensores dos dispositivos móveis como fonte de dados sobre comportamento. Nesse modelo computacional o dispositivo constantemente captura informações de contexto, como acelerômetro, chamadas, mensagens, luminosidade e localização, para então formar uma série de contextos numa linha do tempo, como se fossem retratos de cada momento. Essa série de retratos podem identificar variações no comportamento, que como consequência, podem auxiliar no gerenciamento de transtornos neuropsiquiátricos, e quando utilizado em escala suficiente, poderia construir perfis epidemiológico dos transtornos gerenciados.

Este trabalho propõe um modelo para identificação de padrões de comportamento em pessoas com transtornos neuropsiquiátricos baseado em históricos de contextos de forma que o acompanhamento de um indivíduo possa ser utilizado como base no tratamento de outros indivíduos, sendo que se utilizado em escala o modelo poderá ser capaz de montar perfis epidemiológicos dos transtornos em tratamento na plataforma.

O modelo é baseado na premissa de que a disseminação e utilização em massa de dispositivos móveis criou uma oportunidade de utilizar estes dispositivos como ferramenta de identificação de comportamento, e que estes podem ser utilizados para suportar o gerenciamento dos transtornos neuropsiquiátricos. E que além do gerenciamento de apenas um indivíduo, tal abordagem permitiria: (1) comparar e adaptar o tratamento de um indivíduo com sintomas semelhantes em outro indivíduo em tratamento, e (2) construir perfis epidemiológicos dos transtornos mentais utilizando as informações sócio-demográficas e de tratamento existentes na plataforma.

Este trabalho apresenta o modelo, a arquitetura, um protótipo e avaliação do modelo, bem como estuda os limites e necessidades de utilização em larga escala para que os perfis possam ser construídos. As principais contribuições são: (1) o auxílio ao diagnóstico baseado em julgamento clínico utilizando históricos de contexto de indivíduos em fase final de tratamento e indivíduos na fase inicial como forma de sugestão de caminho ao profissional de saúde, (2) a inclusão do profissional de saúde mental como agente chave na definição de intervenções e da opinião clínica como parte da escolha de algoritmos adaptativos para diagnóstico, e (3) a construção de perfis epidemiológicos psiquiátricos utilizando o histórico de contextos e diagnósticos dos profissionais.

Palavras-Chave: Computação Ubíqua. Sensibilidade de Contextos. Histórico de Contextos. Análise de Similaridade.

ABSTRACT

Neuropsychiatric disorders have been neglected by public health attention during a large period of time, often due to low mortality that was directly related to mental health problems. This behavior translated into low investments in research and medical practices. As consequence neuropsychiatric disorders are between the diseases with largest economic and social burden. Considering that a good part of these disorders can be identified based on patient behavior, and that smartphones and wearables are every day more available in the overall society, it is fair to imagine that the usage of these devices could help in the diagnosis process, in treatment and in a better understanding of these disorders and how they affect the society through a set of epidemiological profiles.

Ubiquitous computing, more specifically in the application and usage of context history, is a way of taking advantage of mobile devices sensors as a data source of human behavior. In this computational model, the device is frequently recording information about the user's context, such as accelerometer, incoming and outgoing calls, messages, ambient luminosity and location, so that it can derive a set of contexts in a timeline, as if they were snapshots of each moment. This set of snapshots can identify behavior changes, that can be used in the management of neuropsychiatric disorders, and if applied in a large scale, could be enough to build epidemiological profiles of the managed disorders.

This thesis proposes a model to identify behavioral patterns in people with neuropsychiatric disorders based on context history so that the treatment of a given patient can be used as basis for the treatment of other patients, and that when used in scale, this model could be capable to building epidemiological profiles of disorders being managed and treated in the platform.

The model is based in the hypothesis that the ubiquitous availability of mobile devices and the massive usage of them have created an opportunity to use these devices as a way of identifying behavior, and that it could be used to support the management of neuropsychiatric disorders. And that beyond the management of a single person, this approach could: (1) compare and adapt the treatment of a given person based on another person with similar symptoms that is or have been under treatment, and (2) build epidemiological profiles of mental disorders using the social and demographic data as well as the diagnosis and treatment data available in the platform.

This thesis describes the model, architecture, a prototype and well as the usage of the model, studies the limits and the necessity of a large-scale usage so that the profiles can be built. The major contribution are: (1) diagnosis support based on clinical judgement using context history of patients in advanced treatment stages with the history of patients in the initial phase, (2) the inclusion of mental health professional as a key resource in the definition of interventions and in considering the professionals clinical judgment as part of the algorithm definition in the diagnosis process and (3) the building of psychiatric epidemiological profiles using context history and mental health professionals diagnosis.

Keywords: Ubiquitous Computing. Context-Aware Computing. Context History. Similarity Analysis.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1: Ontologia para depressão no modelo Hígia | 28 |
| Figura 2: Processo de classificação com 5 vizinhos | 34 |
| Figura 3: Árvore de decisão para jogar tênis | 35 |
| Figura 4: Exemplo de rede MLP com três camadas, sendo uma oculta | 35 |
| Figura 5: Resumo da seleção | 41 |
| Figura 6: Aplicativo Kokoro do projeto FLATT para intervenção baseada em TCC | 43 |
| Figura 7: Relatório do MedLink para acompanhamento profissional | 44 |
| Figura 8: Componentes do MONARCA 2.0 utilizados para construção dos relatórios | 45 |
| Figura 9: Tecnologia vestível da plataforma PSYCHE | 46 |
| Figura 10: Fluxo de informações na arquitetura do PREVENTER | 47 |
| Figura 11: Ferramenta de monitoramento do diário virtual no PRISM..... | 48 |
| Figura 12: Arquitetura e dispositivos do SleepSight | 49 |
| Figura 13: Fluxo de informação entre os conceitos | 55 |
| Figura 14: Relação entre diagnóstico, sensoriamento e contexto. | 57 |
| Figura 15: Relação entre epidemiologia, indicadores e sensoriamento passivo no modelo..... | 59 |
| Figura 16: Paciente monitorado com ActiWatch e dados de sensoriamento | 60 |
| Figura 17: Processo de construção dos perfis epidemiológicos | 61 |
| Figura 18: Fluxograma do modelo no primeiro encontro com o profissional..... | 62 |
| Figura 19: Fluxograma do modelo nos encontros subsequentes | 64 |
| Figura 20: Exemplo de matriz de comportamento | 66 |
| Figura 21: Matriz de comportamento em representação binária..... | 67 |
| Figura 22: Exemplo de diagnóstico até determinação de indicadores | 70 |
| Figura 23: Exemplo de conversão de diagnóstico em indicadores | 71 |
| Figura 24: Exemplo de indicadores, seleção de estratégia até definição de sensoriamento..... | 72 |
| Figura 25: Exemplo de conversão de indicadores em sensores | 73 |
| Figura 26: Interação entre sensoriamento, dispositivo móvel, paciente e repositório de sensoriamento | 74 |
| Figura 27: Exemplo de conversão de sensoriamento em indicadores e de indicadores em contexto..... | 75 |
| Figura 28: Exemplo no uso do histórico de contextos para suportar o tratamento | 76 |
| Figura 29: Arquitetura em alto nível proposta para o modelo..... | 78 |
| Figura 30: Visão geral das classes básicas da ontologia de comportamento..... | 79 |
| Figura 31: Visão detalhada das classes de contexto | 80 |

| | |
|--|-----|
| Figura 32: Classes relacionadas ao perfil sociodemográfico | 81 |
| Figura 33: Visão detalhada da ontologia em relação a classe Pessoa..... | 82 |
| Figura 34: Visão detalhada das classes que definem tempo e espaço | 82 |
| Figura 35: Ilustração do parâmetro i por cada janela de tempo t para o indivíduo de controle #4 | 85 |
| Figura 36: Ilustração do parâmetro i por cada janela de tempo t para o indivíduo com depressão #4..... | 86 |
| Figura 37: Representação gráfica do primeiro <i>eigenbehavior</i> para os indivíduos de controle #3 e #4 | 87 |
| Figura 38: Representação gráfica do primeiro <i>eigenbehavior</i> para indivíduos com depressão #3 e #4..... | 87 |
| Figura 39: Expressão da busca SPARQL para identificação casos de depressão profunda por sexo e faixa etária..... | 91 |
| Figura 40: Expressão de busca para contagem de casos incidentes por ano por transtorno..... | 98 |
| Figura 41: Expressão de busca SPARQL para identificação de comorbidades | 99 |
| Figura 42: Expressão de busca SPARQL para resposta da questão de competência 4 | 100 |
| Figura 43: Expressões de busca para medicação com maior índice de remissão por transtorno, lado esquerdo a expressão por classe de transtorno, ao lado direito por instância de transtorno | 101 |
| Figura 44: Gráfico de desempenho de inferência..... | 103 |

LISTA DE TABELAS

| | |
|--|-----|
| Tabela 1: Questões de pesquisa para revisão sistemática..... | 38 |
| Tabela 2: Frases de busca nas bases acadêmicas. | 39 |
| Tabela 3: Estratégia de busca | 40 |
| Tabela 4: Resumo da estratégia de seleção. | 40 |
| Tabela 5: Comparativo geral entre os trabalhos relacionados. | 51 |
| Tabela 6: Comparação de dispositivos, algoritmos e indicadores | 52 |
| Tabela 7: Comparação de tipo de intervenções e suporte ao profissional..... | 53 |
| Tabela 8: Comparação da acurácia de cada classificador..... | 88 |
| Tabela 9: Comparação da distância da rotina entre o indivíduo com depressão #2 e os demais indivíduos. | 90 |
| Tabela 10: Casos de depressão por faixa etária e sexo nos dados de (GARCIA-CEJA <i>et al.</i> , 2018) | 91 |
| Tabela 11: Axiomas de equivalência para classes inferidas..... | 92 |
| Tabela 12: Casos de depressão por escolaridade, estado civil e situação empregatícia em relação aos dados de (GARCIA-CEJA <i>et al.</i> , 2018)..... | 93 |
| Tabela 13: Lista de pacientes simulados por região e data..... | 94 |
| Tabela 14: Distribuição de características dos pacientes em Morrinhos | 94 |
| Tabela 15: Distribuição de características simuladas por grupo de transtorno dos pacientes de Itajubá | 95 |
| Tabela 16: Distribuição de características simuladas dos pacientes de Salvador | 97 |
| Tabela 17: Resultado das expressões de busca da questão de competência 5..... | 101 |
| Tabela 18: Resultado da avaliação de desempenho, tempo em segundos por inferência..... | 104 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|-------|--|
| APA | <i>American Psychology Association</i> |
| API | <i>Application Programming Interface</i> |
| DSM | <i>Diagnostic and Statistical Manual of Mental Disorders</i> |
| EHR | <i>Electronic Health Records</i> |
| GAD-7 | <i>Generalized Anxiety Disorder 7-items</i> |
| HRV | <i>Heart Rate Variability</i> |
| ICD | <i>International Classification of Diseases</i> |
| KNN | <i>K-Nearest Neighbors</i> |
| MLP | <i>Multi-Layer Perceptron</i> |
| OMS | <i>Organização Mundial da Saúde</i> |
| PANSS | <i>Positive and negative symptom scale</i> |
| PHQ-8 | <i>Patient Health Questionnaire 8-items</i> |
| PHR | <i>Personal Health Records</i> |
| SMA | <i>Signal Magnitude Area</i> |
| SRM | <i>Social Rhythm Metric</i> |
| SVM | <i>Support Vector Machine</i> |
| VAD | <i>Modelo Valence-Arousal-Dominance</i> |

SUMÁRIO

| | |
|--|-----|
| 1 INTRODUÇÃO..... | 18 |
| 1.1 Definição do problema e questão de pesquisa..... | 19 |
| 1.2 Objetivos | 22 |
| 1.3 Metodologia..... | 22 |
| 1.4 Escopo da tese..... | 23 |
| 1.5 Estrutura do texto | 23 |
| 2 REVISÃO BIBLIOGRÁFICA | 25 |
| 2.1 Computação Ubíqua..... | 25 |
| 2.2 Contextos e Históricos de Contextos..... | 26 |
| 2.3 Tecnologia vestível | 27 |
| 2.4 Ontologias e web semântica..... | 27 |
| 2.5 Transtornos mentais e classificações (ICD e DSM)..... | 30 |
| 2.6 Reconhecimento de padrões no comportamento humano | 32 |
| 2.7 Aprendizado de máquina e classificadores supervisionados | 33 |
| 2.8 Epidemiologia e transtornos mentais | 36 |
| 3 TRABALHOS RELACIONADOS | 38 |
| 3.1 Planejamento da revisão..... | 38 |
| 3.2 Bases, estratégia de busca e critérios | 39 |
| 3.3 Resultados da busca..... | 41 |
| 3.4 AMoSS | 42 |
| 3.5 FINE | 42 |
| 3.6 FLATT | 43 |
| 3.7 MedLink | 44 |
| 3.8 MONARCA I e MONARCA II | 45 |
| 3.9 PSYCHE | 46 |
| 3.10 PREVENTER | 47 |
| 3.11 PRISM | 48 |
| 3.12 SleepSight | 49 |
| 3.13 Comparativo | 50 |
| 4 MODELO EIGENROUTINES | 55 |
| 4.1 Conceitos básicos..... | 55 |
| 4.2 Separação entre sensoriamento e contexto | 58 |
| 4.3 Perfis epidemiológicos | 60 |
| 4.4 Fluxo de processos do modelo | 61 |
| 4.5 Eigenbehaviors e Eigenroutines | 65 |
| 4.6 Cenário de exemplo | 70 |
| 4.7 Arquitetura..... | 76 |
| 4.8 Ontologia Eigenroutines | 79 |
| 5 AVALIAÇÃO..... | 83 |
| 5.1 Metodologia de avaliação | 83 |
| 5.2 Identificação de padrões de atividade em pessoas com depressão utilizando actigrafia.... | 83 |
| 5.3 Construção do perfil epidemiológico baseado na confirmação do diagnóstico..... | 90 |
| 6 CONCLUSÃO..... | 105 |
| 6.1 Limitações da tese | 105 |
| 6.2 Trabalhos futuros..... | 106 |
| 6.3 Artigos publicados relacionados a Tese..... | 106 |

1 INTRODUÇÃO

Transtornos neuropsiquiátricos representam um grande peso econômico e social, cujas estimativas variam entre 14% e 32% da carga global de doenças de acordo com a OMS (VIGO; THORNICROFT; ATUN, 2016). Uma em cada quatro pessoas sofre com algum transtorno mental durante a sua vida e se estima que 322 milhões de pessoas estão sofrendo com depressão e ao menos 420 milhões sofrendo com algum tipo de transtorno neuropsiquiátrico todos os dias (WORLD HEALTH ORGANIZATION, 2017).

Essa situação está prevista para piorar ao longo dos próximos anos, sendo que transtornos mentais devem se tornar a maior causa de deficiências no planeta até 2030 (WORLD HEALTH ORGANIZATION, 2012), enquanto se estima que 30 milhões de pessoas tentem e 1.5 milhões de pessoas consigam se suicidar neste mesmo período (BERTOLOTE; FLEISCHMANN, 2002).

Além do fardo social e econômico, transtornos mentais também se mostram relacionados a doenças físicas. O estresse causa uma maior susceptibilidade ao resfriado (COHEN; TYRRELL; SMITH, 1991), atrasos na cicatrização com aumento de possibilidades de infecções (ROJAS *et al.*, 2002), e diversas disfunções imunológicas (GODBOUT; GLASER, 2006), enquanto depressão e transtorno bipolar se mostram relacionados a problemas como obesidade (BLAINE, 2008), câncer (REICHE; NUNES; MORIMOTO, 2004) e problemas cardiovasculares (VAN MELLE *et al.*, 2004).

E não menos importante, existe um descompasso entre a necessidade de atendimento e a quantidade de profissionais de saúde mental. Na Europa, a OMS estima que 3 em cada 4 pessoas que sofrem de depressão profunda não recebem um tratamento adequado, 45% da população mundial vive em um país com menos de 1 psiquiatra para cada 100 mil habitantes (WHO EUROPE, 2014), e no Brasil a estatística é de aproximadamente 3 psiquiatras e 9 psicólogos por 100 mil habitantes (WORLD HEALTH ORGANIZATION, 2011).

Historicamente as políticas e decisões sobre investimentos em saúde pública eram em sua maioria orientadas a partir de estatísticas de mortalidade. Como resultado, as desordens neuropsiquiátricas receberam menos investimento e atenção da comunidade acadêmica quando comparadas a doenças cardiovasculares, câncer e doenças contagiosas (USTÜN, 1999).

Isso se traduziu em práticas baseadas em técnicas descritivas e geralmente não baseadas em evidências. Diferente de outras áreas da medicina, são poucos os testes clínicos objetivos e dispositivos médicos especializados utilizados de forma rotineira no tratamento de transtornos mentais.

De forma complementar, a última década apresentou um grande avanço tecnológico em termos de plataformas de computação distribuída, algoritmos e ferramentas de aprendizado de máquina, sendo que na atualidade estas ferramentas estão rápidas o suficiente para analisar dados massivos em pouco tempo.

Aliando essa capacidade de processamento com a ubiquidade de dispositivos móveis, especialmente *smartphones*, presentes no dia-a-dia de grande parte da população, novas abordagens para estes problemas sociais e novas formas para compreender o comportamento e antecipar as ações de indivíduos estão surgindo (LAZER *et al.*, 2009; PEJOVIC; MUSOLESI, 2015).

Uma das formas de aplicar essas técnicas é a utilização de histórico de contextos, que é a capacidade de um sistema de construir séries temporais vinculadas à localização e atividades

de um indivíduo visando compreender a evolução de seu contexto ao longo do tempo (DA ROSA; BARBOSA; RIBEIRO, 2016; HONG *et al.*, 2009).

É possível observar um crescente interesse nas aplicações de tais técnicas no âmbito de saúde mental (FIRTH; TOROUS; YUNG, 2016). Os exemplos de aplicações vão desde a correlação de traços de personalidade e formas de comunicação (STOPCZYNSKI *et al.*, 2014), explicação de mudanças comportamentais (ALSHAMSI *et al.*, 2015), classificação de estados psicológicos baseado em medidas fisiológicas (BAVARESCO *et al.*, 2020), até a o uso de dispositivos móveis para realizar predições quanto a possibilidade de depressão pós parto (JIMENEZ-SERRANO; TORTAJADA; GARCIA-GOMEZ, 2015), na identificação de relapso bipolar (ABDULLAH *et al.*, 2016; FAURHOLT-JEPSEN *et al.*, 2013) e nos cuidados para pessoas com depressão (PETRY *et al.*, 2016, 2019) e ansiedade (DIAS *et al.*, 2019). Esta tese descreve um modelo computacional que busca contribuir na identificação de padrões de comportamento de indivíduos com transtornos neuropsiquiátricos e no entendimento das características epidemiológicas destes transtornos.

1.1 Definição do problema e questão de pesquisa

O modelo proposto neste trabalho aborda dois grupos de problemas relacionados a transtornos neuropsiquiátricos: (a) problemas no diagnóstico e (b) problemas de relapso.

1.1.1 Problemas no diagnóstico

Uma forte dependência com o julgamento clínico durante o processo de diagnóstico e tratamento de transtornos neuropsiquiátricos foi identificada por Lobbestael (LOBBESTAEL; LEURGANS; ARNTZ, 2010).

No processo de diagnóstico existem dois pontos chaves, sendo um baseado no relato do paciente e o outro na coleta do histórico de sintomas através de entrevistas. Ficar dependente da lembrança do paciente torna a informação subjetiva e com viés de recordações (BEN-ZEEV *et al.*, 2012), e este diagnóstico se torna especialmente desafiador quando o processo cognitivo do paciente já está prejudicado pelo próprio transtorno (GREEN, 2006). Diversas escalas de saúde mental foram propostas no intuito de resolver o problema de subjetividade (RUSH; FIRST; BLACKER, 2008), porém existem indícios que a utilização destas pode levar o profissional a conclusões incorretas (SHEDLER; MAYMAN; MANIS, 1993).

O processo de diagnóstico e prescrição de tratamento para transtornos mentais é desafiadora mesmo para profissionais treinados quando se leva em consideração a subjetividade do processo de diagnóstico, o viés de recordação de eventos, e o alto grau de similaridade entre sintomas de diferentes transtornos (HENRY *et al.*, 1992). Thomas Insel (INSEL *et al.*, 2010) ressaltou em seu trabalho a necessidade de se utilizar critérios de diagnósticos mais objetivos para construção de um sistema de diagnóstico confiável e capaz de capturar as disfunções para realizar uma definição capaz de distinguir as fronteiras entre os transtornos.

Portanto o primeiro fator motivador para questão de pesquisa é se modelos computacionais baseados em históricos de contextos poderiam suportar identificação de transtornos neuropsiquiátricos baseados em critérios mais objetivos, como a classificação de um indivíduo baseado na sua rotina, observando que muitos dos transtornos são de natureza comportamental.

1.1.2 Problemas com relapso

Muitos transtornos neuropsiquiátricos não podem ser curados completamente e se tornam condições para toda a vida do paciente, o qual precisa lidar com períodos de remissão e de relapsos (JOHNSON; LEAHY, 2004).

O tratamento nesses casos é focado em evitar relapsos realizando algum tipo de intervenção e acompanhamento nos primeiros sinais de deterioração, onde em muitos casos os sinais podem ser identificados antes do relapso completo, permitindo uma intervenção mais efetiva (KLOSTERKÖTTER *et al.*, 2001).

O problema nesses casos é que os primeiros sinais não são identificados pelos pacientes, familiares ou profissionais, seja pela falta de exames periódicos ou pelos problemas de conformidade ou de viés de recordação dos eventos por parte do paciente (PETRY *et al.*, 2016).

Esses problemas na identificação do relapso resultam numa maior necessidade no uso de fármacos, cujos efeitos colaterais podem ser severos. Lítio, o fármaco mais utilizado para estabilização de humor no tratamento de transtorno bipolar, pode levar a tremores e ganho de peso como efeito colateral (GITLIN, 2016). Medicamentos antipsicóticos podem levar a sedação, ganho de peso e disfunções sexuais (RUMMEL-KLUGE; KOMOSSA, 2010).

Portanto uma forma mais sistemática e objetiva para identificar sinais de relapsos pode ser útil tanto para evitar o uso desnecessário de recursos farmacológicos, quanto para evitar sofrimento desnecessário para pacientes com transtornos incuráveis.

O segundo fator motivacional desta tese é como um modelo computacional poderia suportar o acompanhamento do paciente de forma a identificar os primeiros sinais e alertar um familiar ou profissional, bem como agir a fim de reduzir a gravidade da situação.

1.1.3 Questões de pesquisa

Este trabalho aborda o problema de identificação e acompanhamento de indivíduos com transtornos neuropsiquiátricos a partir da comparação de históricos de contextos, onde o histórico de outros indivíduos em tratamento possa ser utilizado para comparação do histórico do indivíduo em processo de diagnóstico e tratamento, a fim de gerar benefícios a todas as partes envolvidas (paciente, familiares e profissionais), bem como a sociedade em que eles estão.

O problema é dividido em duas questões gerais de pesquisa, onde a primeira questão geral é relacionada com os indivíduos:

“Como deve ser um modelo computacional para identificar padrões comportamentais em indivíduos com transtornos neuropsiquiátricos a partir do histórico de contextos de forma a suportar o tratamento e acompanhamento de outros indivíduos? ”

E complementando a ideia da primeira questão, existe outra necessidade latente nos problemas descritos nas seções anteriores, cuja questão pode ser descrita como:

“É possível utilizar esse modelo de auxílio de indivíduo para construção de perfis epidemiológicos de transtornos neuropsiquiátricos? ”

Ao qual levaria a última indagação aberta para trabalhos futuros: Quais as possibilidades e oportunidades de tal modelo em contribuir para políticas de saúde pública ou aplicação de terapias e exercícios preventivos?

A primeira questão é importante, pois se tal modelo computacional tornar profissionais mais eficientes e reduzir o sofrimento dos pacientes, traria um ganho significativo para a sociedade. Essa questão se fundamenta em dois pontos: (1) o primeiro ponto é que o julgamento clínico e o suporte ao profissional de saúde mental devem sobrepor aos aspectos tecnológicos, uma vez que a manifestação dos transtornos pode variar de forma a dificultar a precisão de avaliações objetivas que não são baseadas em avaliações clínicas (eg. “Se o paciente dorme muito ele necessariamente está deprimido” não é verdade para todos os indivíduos), (2) o segundo ponto é que considerando que o ser humano é um ser de rotina e que sua variação de rotina está diretamente vinculada ao comportamento do indivíduo, então deve ser possível comparar a variação do histórico de contextos como forma de identificar melhores opções para tratamentos de transtornos neuropsiquiátricos.

A segunda questão remete a necessidade de fortalecer os estudos de epidemiologia psiquiátrica para que as causas dos problemas sejam identificadas e corrigidas em suas fases iniciais. A identificação dos perfis epidemiológicos traria evidências quanto ao andamento e efetividade das políticas de saúde pública.

Sendo assim, para contribuir com o estado da arte e responder as questões apresentadas, a seguinte proposição é defendida:

“Um modelo computacional baseado em históricos de contextos para diagnóstico, tratamento e acompanhamento de indivíduos com transtornos neuropsiquiátricos é capaz de suportar o trabalho de profissionais de saúde mental. O benefício de tal modelo a profissionais e pacientes se deve a capacidade de acompanhar mudanças comportamentais com uma resolução inviável de se conseguir através dos meios tradicionais e, portanto, é capaz de direcionar e prover dados objetivos quanto aos resultados do tratamento, comparando o tratamento e mudanças no comportamento do paciente em questão com a avaliação de outros profissionais em relação a outros indivíduos em tratamento, sendo que tal abordagem teria subsídio de informações necessárias para construção de perfis epidemiológicos de transtornos neuropsiquiátricos.”

Baseado nas questões de pesquisa e na proposição foram definidas as seguintes questões específicas para guiar a investigação:

- 1 Como deve ser o modelo computacional capaz de suportar os elementos da proposição?
- 2 Como representar e modelar o histórico de contextos de forma que padrões comportamentais (rotinas) sejam identificados?
- 3 Como identificar os transtornos neuropsiquiátricos utilizando os padrões comportamentais baseado em histórico de contextos extraídos de sensores de dispositivos móveis?
- 4 Como comparar diferentes padrões comportamentais utilizando históricos de contextos?

1.2 Objetivos

O objetivo geral desta tese é propor um modelo computacional baseado em históricos de contextos capaz de identificar padrões de comportamento para auxiliar a identificação e tratamento de pessoas com transtornos neuropsiquiátricos, tendo por princípio utilizar os dados capturados para identificação dos transtornos para auxiliar tanto o profissional de saúde mental quanto a definição de políticas públicas de saúde mental a partir da identificação de perfis epidemiológicos.

Este objetivo geral permite derivar os seguintes objetivos específicos:

- Identificar o estado da arte no uso de dispositivos móveis para gerenciamento de transtornos neuropsiquiátricos (Resposta a questão específica 1);
- Criar um modelo computacional para suportar o diagnóstico, tratamento e acompanhamento (Resposta a questão específica 1);
- Modelar o contexto e os históricos de contextos para suportar o modelo definido (Resposta a questão específica 2);
- Definir e comparar algoritmos e técnicas para realização de identificação de padrões e transtornos (Resposta as questões específicas 3 e 4);
- Codificar um protótipo da plataforma e módulos necessários para avaliação do modelo;
- Avaliar a precisão da identificação de transtornos utilizando histórico de contextos (Resposta a questão específica 4).

1.3 Metodologia

A metodologia para validação da proposição está dividida em quatro etapas: (1) identificação do estado da arte no uso de computação móvel e ubíqua no tratamento ou acompanhamento de transtornos neuropsiquiátricos, (2) definição do modelo para suporte da proposição, (3) definição e codificação da plataforma com suporte ao modelo, (4) avaliação dos resultados e definição da precisão do modelo.

A primeira etapa teve por objetivo compreender o estado da arte no que tange os problemas ao qual este modelo busca contribuir como parte da solução. Nesta etapa foram avaliados modelos, algoritmos, técnicas, equipamentos e dispositivos computacionais, abordagens quanto ao tratamento e uso de dispositivos, transtornos em maior e menor evidência nas pesquisas e o interesse da comunidade acadêmica na última década.

A segunda etapa teve por objetivo definir um modelo capaz de suportar a proposição, onde profissionais, pacientes e familiares possam interagir, e onde o tratamento possa ser acompanhado de forma objetiva. Neste modelo se visa extensibilidade, uma vez que na primeira etapa foi identificado que os trabalhos tendem a focar em aspectos ou técnicas bem específicas para cada situação e, portanto, o modelo se direcionou como uma forma de integrar as técnicas atuais a fim de facilitar o tratamento e permitir a identificação de perfis epidemiológicos.

A terceira etapa é a concretização do modelo em forma de software, onde a arquitetura será especificada e codificada atendendo a requisitos de extensibilidade, bem como serão comparados e especificados os algoritmos necessários para suprir as necessidades do modelo.

A quarta etapa tem por objetivo avaliar os resultados dos experimentos e identificar os limites do modelo e da plataforma na identificação de transtornos e perfis epidemiológicos.

1.4 Escopo da tese

Esta tese busca avaliar um modelo para identificação de padrões de comportamento para suporte ao tratamento e acompanhamento de transtornos neuropsiquiátricos de forma que o modelo permita construir perfis epidemiológicos a partir das informações capturadas.

Dessa forma, se define que o escopo será na identificação de rotinas a partir de um histórico de contextos, bem como na modelagem dos conceitos e relações dos dados, na identificação e aplicação de algoritmos para diagnóstico e construção de perfis epidemiológicos a partir dos conceitos e dados capturados no modelo.

Não serão analisados em profundidade aspectos como segurança, privacidade, protocolos, tolerância a falhas e utilização das informações de epidemiologia na definição de políticas de saúde pública.

1.5 Estrutura do texto

Este trabalho está organizado da seguinte forma:

- **Capítulo 2 - Revisão bibliográfica:** apresenta os fundamentos que subsidiam o modelo e proposição desta tese. Neste capítulo são abordados conceitos necessários para o entendimento da proposição, bem como conceitos empregados na construção do modelo e da plataforma;
- **Capítulo 3 - Trabalhos relacionados:** apresenta uma análise do estado da arte na utilização de computação móvel e ubíqua no diagnóstico, tratamento e acompanhamento de transtornos mentais, realiza uma comparação entre os trabalhos e destaca a influência dos mesmos na proposição e no modelo Eigenroutines.
- **Capítulo 4 - Modelo Eigenroutines:** apresenta o modelo computacional e arquitetura que suportam a proposição desta tese. Este capítulo descreve os princípios básicos do modelo e arquitetura de software, bem como os principais módulos e funcionalidades;
- **Capítulo 5 - Avaliação:** apresenta duas avaliações, uma da aplicação do modelo para identificação de transtornos em pacientes com depressão utilizando dados obtidos de tecnologia vestível (*wearables*) e uma avaliação da construção de um perfil epidemiológico;
- **Capítulo 6 - Conclusão:** apresenta as considerações finais deste trabalho, contribuições e trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo revisa os conceitos básicos para o entendimento dos trabalhos relacionados no capítulo 3 e do modelo e plataforma no capítulo 4, e está resumido nas seguintes seções:

- **Computação ubíqua:** base teórica para os históricos de contextos e identificação de atividades, necessária para captura e análise de informações do comportamento humano;
- **Ontologias:** base teórica para modelagem do conhecimento e troca de informações entre sistemas, sendo relevante para a classificação de transtornos mentais e construção de perfis epidemiológicos;
- **Transtornos mentais e classificações:** Necessário para o entendimento dos diferentes grupos de transtornos, e das classificações mais difundidas na comunidade médica e acadêmica;
- **Reconhecimento de padrões no comportamento humano:** Base teórica da aplicação de aprendizado de máquina em dados capturados por sistemas ubíquos com o objetivo de reconhecer padrões no comportamento humano, e utilizar esses padrões para identificar transtornos;
- **Epidemiologia e transtornos mentais:** Base teórica necessária para o entendimento da epidemiologia e como a mesma é aplicada a transtornos mentais.

2.1 Computação Ubíqua

A visão de computação ubíqua conforme apresentada por Weiser em sua obra seminal (WEISER, 1991) e depois refinada para o termo computação pervasiva é essencialmente a ideia de ambientes inteligentes e integrados ao cotidiano de seus usuários, onde objetos do dia-a-dia podem se comunicar e cooperar para reduzir assim o esforço para a realização das atividades (WANT, 2010).

O termo computação pervasiva foi cunhado como uma proposta de evolução em relação aos experimentos realizados em meados de 1970, e é a união das áreas de estudo de sistemas distribuídos e computação móvel, fazendo uso destas tecnologias para atingir seus principais objetivos e podem ser caracterizados como (SATYANARAYANAN, 2001; SEZER; DOGDU; OZBAYOGLU, 2018):

- **Espaços Inteligentes:** É definido como um espaço com tecnologia embarcada, que permite a sua comunicação com objetos dentro de seus limites, ou com outros espaços inteligentes;
- **Invisibilidade:** É a característica que é alcançada quando a tecnologia embarcada se torna invisível para a consciência dos usuários, permitindo que o uso e interação natural com o espaço inteligente impliquem em respostas naturais e inteligentes do ambiente;
- **Escalabilidade localizada:** É a característica na qual os espaços inteligentes passam fornecer capacidade computacional para dispositivos com menos capacidade, seja de processamento, banda ou energia. Atualmente a capacidade dos dispositivos

móveis tem sido limitada a quantidade de energia disponível, e essa característica da computação pervasiva conforme indicada por Satyanarayanan pode ser menos relevante quando comparada as demais;

- **Esconder as diferentes condições:** Característica na qual ambientes podem ter condições distintas de “inteligência”, o que pode afetar a característica de invisibilidade, uma vez que o usuário perceberia uma diferença entre ambientes. O autor sugere a possibilidade de ser compensada pelos dispositivos móveis inteligentes.

Sistemas que aplicam estas características idealizadas por Weiser vêm sendo explorados em diversos domínios de conhecimento, cobrindo áreas como saúde (*u-health*), acessibilidade (*u-accessibility*), aprendizado (*u-learning*), comércio (*u-commerce*) e jogos (*u-games*), onde atualmente técnicas relacionadas a históricos de contextos e predição de contextos são tendências de pesquisa (BANOS; HERVÁS, 2019; BARBOSA *et al.*, 2018; BARBOSA, 2015).

2.2 Contextos e Históricos de Contextos

Sistemas orientados a contexto são definidos como sistemas capazes de examinar e reagir a mudanças no contexto do usuário, sendo o contexto todas as informações relevantes ao usuário em um determinado momento do tempo, também levando em conta localização do usuário, bem como pessoas e dispositivos próximos ao usuário (SEZER; DOGDU; OZBAYOGLU, 2018).

Brooks propõe cinco questões para guiar o projeto de dispositivos computacionais sensíveis a contexto, questões estas que quando respondidas proveem informações suficientes para inferência do contexto do usuário do sistema, estas cinco questões são: Quando, Onde, O Que, Quem e Por que (BROOKS, 2003).

Estas questões podem ser divididas em categorias de maturidade devido às tecnologias existentes e difundidas. “Quando” e “Onde” podem ser definidas com precisão aceitável e sem consumo de muitos recursos por dispositivos móveis com GPS e sincronização de data e hora via rede GSM.

“O que” está relacionado ao que o usuário está fazendo em um determinado momento, e pode ser inferido pelos sensores e dados capturados por dispositivos móveis, como acelerômetro, sensor de luminosidade, chamadas e trocas de mensagens, ritmo cardíaco, microfones e câmeras.

“Quem” é uma questão considerada desafiadora pelo autor, uma vez que não é apenas a classificação de nome e idade, mas sim a relação entre o usuário e outras pessoas a sua volta. Esta característica será parcialmente determinada pela conexão da conta em uma rede social permitindo ao sistema determinar relações e informações do usuário.

A questão “Por que” é definida como possivelmente a mais complexa de todas, uma vez que a motivação por trás de uma ação pode ser desconhecida pelo próprio usuário, e é uma questão que ainda continua como um desafio a ser pesquisado em trabalhos futuros.

A partir destes conceitos básicos do que forma um contexto, Rosa (ROSA *et al.*, 2015) sugere que arquiteturas para sistemas orientados a contexto utilizem não apenas o contexto no momento atual, mas que armazenem contextos conhecidos para uso futuro do forma a antecipar uma decisão futura, ou tornar as decisões do presente mais precisas. O uso de contextos

passados para adaptar o software e as decisões sobre o contexto presente é chamado de histórico de contextos (HONG *et al.*, 2009), e aplicações que identificam potenciais estados futuros de contexto são chamadas de computação móvel antecipatória (PEJOVIC; MUSOLESI, 2015) ou predição de contextos (DA ROSA; BARBOSA; RIBEIRO, 2016).

Dentre as diversas aplicações de histórico de contextos e predições de contextos, é possível destacar seu uso como forma para gerenciar perfis educacionais de forma a se adaptar a evolução de um determinado aluno (WAGNER; BARBOSA; BARBOSA, 2014), adaptar e escolher o melhor algoritmo para prever o próximo estado do contexto baseados no histórico de contexto conhecido (DA ROSA; BARBOSA; RIBEIRO, 2016), avaliar a fertilidade e produtividade de solos em cenários de agricultura de precisão (HELPER *et al.*, 2019), e como forma de construção de um diário de eventos do dia-a-dia de um indivíduo para auxiliar no tratamento de ansiedade e depressão (BAVARESCO *et al.*, 2020; DIAS *et al.*, 2019; PETRY *et al.*, 2019).

2.3 Tecnologia vestível

Recentes avanços tecnológicos em relação à miniaturização de sensores e dispositivos de comunicação abriram novas possibilidades na imersão de dispositivos computacionais de forma invisível no dia-a-dia das pessoas. Essa utilização do uso especializado da tecnologia em acessórios ou vestimentas é conhecido como tecnologia Vestível (mais conhecido pelo termo em inglês: *Wearables*).

Comparado a computação móvel tradicional, os *wearables* tem vantagens sobre os aspectos de monitoramento do usuário e do seu entorno, já que muitas vezes são partes da vestimenta e dotado de funcionalidades como pedômetro, monitor cardíaco, identificação de luminosidade e atividade via acelerômetro. FitBit Charge, Apple Watch, Samsung Gear, Garmin Vivoactive HR são alguns dos exemplos comerciais com essas capacidades.

Devido a essa proximidade e vantagem em termos de sensoriamento, muito já vem sendo discutido sobre a aplicabilidade clínica dos *wearables*, como por exemplo, no monitoramento de pessoas com doença de Parkinson, ou pacientes em recuperação de derrames (BONATO, 2009).

Em termos de saúde mental, a utilização dos sensores presentes nos *wearables* mostrou um aumento na precisão do diagnóstico de transtorno bipolar durante a avaliação da plataforma AMoSS (PALMIUS *et al.*, 2014), enquanto a plataforma PSYCHE propôs uma camiseta dotada de sensores para capturar biosinais e identificar variações de humor em indivíduos com transtorno bipolar (VALENZA *et al.*, 2013).

No âmbito desta tese, a plataforma apresenta conceitos que permitiriam o uso de sensores de *smartphones* e de *wearables* para determinar o padrão de comportamento dos indivíduos e avaliar as atividades utilizando algoritmos já propostos por trabalhos anteriores (FAURHOLT-JEPSEN *et al.*, 2015; KERZ *et al.*, 2016; OSIPOV, 2016).

2.4 Ontologias e web semântica

No contexto da ciência da computação, uma ontologia é definida como uma série de primitivas utilizadas para modelar um domínio de conhecimento, tipicamente representadas por classes, atributos e relações (GRUBER, 2009).

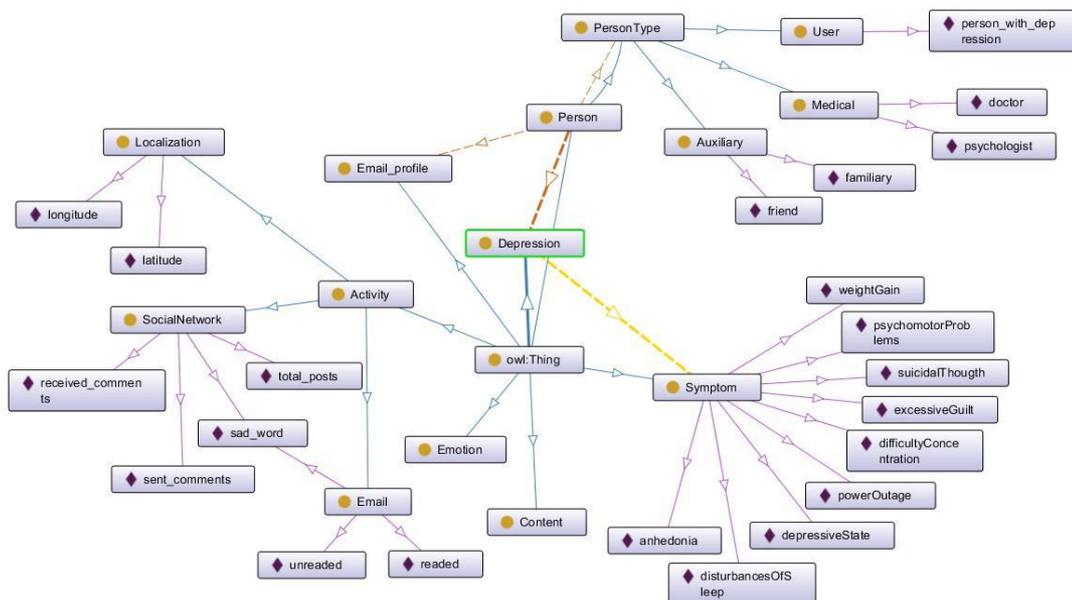
Ontologias são geralmente definidas de forma a abstrair as estruturas de dados e estratégias de implementações, e por este motivo são ditas como parte do nível “semântico” da informação, ao invés das camadas lógicas ou físicas das bases de dados, e é esta característica independente do modelo físico que permite a ontologias conectar bases de dados heterogêneas de sistemas distintos, especificando as interfaces baseadas na representação do conhecimento (GRUBER, 2009).

Ontologias fazem parte dos padrões da W3C para a web semântica, na qual a mesma é utilizada para especificar um padrão de vocabulários conceituais para o compartilhamento de informações entre sistemas, prover serviços para inferência sobre bases de dados e para publicação de bases de conhecimento reutilizáveis (GRUBER, 2009).

Esta abordagem de compartilhamento de informações ganhou espaço entre organizações globais, e a nova representação do *International Classification of Diseases* (ICD) está sendo remodelada para ter seu vocabulário adaptado para OWL, conforme abordado na seção 2.5.

A figura 1 ilustra um fragmento de uma ontologia de depressão utilizada pelo modelo Hígia, modelo de computação ubíqua que utiliza de interações de uma determinada pessoa em seu dispositivo móvel, redes sociais e e-mail para alertar familiares sobre sinais de depressão. Neste exemplo é possível compreender a natureza hierárquica das classes, todas referenciando o conceito básico *Thing*, e descrevendo as classes relevantes a este domínio de conhecimento.

Figura 1: Ontologia para depressão no modelo Hígia



Fonte: (PETRY *et al.*, 2016).

2.4.1 RDF

O *Resource Description Framework* (RDF) é uma família de especificações da W3C projetada inicialmente para modelagem de meta dados para Web. A linguagem define um modelo simples de grafo para capturar a relação entre recursos usando um conceito conhecido como tripla, e tem por característica a flexibilidade de evolução do modelo sem necessidade da

alteração de todas as aplicações que consomem as informações do modelo em questão (W3C, 2004a).

Uma tripla é uma expressão formada por sujeito, predicado e objeto, e um conjunto de triplas forma o conceito de grafo RDF. Como exemplo, uma forma de representar a frase “A marca do smartphone é Apple” em uma tripla RDF seria criar um sujeito denotando “smartphone”, um predicado “tem a marca” e um objeto “Apple”.

2.4.2 OWL

Conforme já destacado no início desta seção, ontologias fazem parte dos padrões da *World Wide Web Consortium* (W3C) para web semântica, e cuja recomendação para construção de modelos é a *Web Ontology Language* (OWL) (W3C, 2009).

Por herdar características do *Resource Description Framework* (RDF), a OWL é capaz de referenciar conceitos presentes em outras ontologias distribuídas entre sistemas distintos, e é esta característica que destaca o seu objetivo de impulsionar a adoção da web semântica (SHADBOLT; HALL; BERNERS-LEE, 2006).

A recomendação da W3C apresenta três sublinguagens da OWL com diferentes graus de expressividade e liberdade para construção de modelos (W3C, 2004b):

- *OWL Lite*: suporta usuários necessitando primariamente de classificação hierárquica e restrições simples, e dada sua simplicidade provê um caminho de migração simplificado para diversas taxonomias existentes;
- *OWL DL*: suporta usuários que necessitam o máximo poder de expressividade sem perder capacidade computacional, ou seja, todas as relações têm garantia de serem computáveis, e todas as computações tem garantia de serem realizadas em tempo finito;
- *OWL Full*: provê maior liberdade de expressividade que a *OWL DL* em troca das garantias computacionais, e permite a uma ontologia aumentar os conceitos em um vocabulário pré-definido (RDF ou OWL).

Cada uma das sublinguagens é uma extensão do seu predecessor mais simples, de forma que as seguintes relações são válidas, mas não o inverso das mesmas (W3C, 2004b):

- Toda ontologia ou conclusão *OWL Lite* válida é uma ontologia ou conclusão *OWL DL* válida;
- Toda ontologia ou conclusão *OWL DL* válida é uma ontologia ou conclusão *OWL Full* válida.

A OWL 2, evolução da *Web Ontology Language*, adicionou mais três sublinguagens (ou *Profiles*, como são chamados no documento), cada qual com restrições sintáticas com relação à especificação estrutural da OWL 2, e com características um pouco mais restritivas que a OWL DL, com objetivo de trocar poder de expressividade por benefícios computacionais (W3C, 2009):

- *OWL 2 EL*: permite algoritmos em tempo polinomial para todas as tarefas de raciocínio padrão, e é particularmente adequado a aplicações com necessidade de ontologias grandes onde é possível realizar a troca de expressividade por garantias de desempenho;

- *OWL 2 QL*: adequado a aplicações com ontologias pequenas e grandes volumes de dados instanciados, onde é útil o acesso aos dados via consultas relacionais;
- *OWL 2 RL*: semelhante ao OWL 2 QL, mas onde o grande volume de informações precisa de manipulação direta nas informações na forma de triplas RDF.

A OWL 2 possui retro compatibilidade com seu predecessor e, portanto, toda ontologia OWL 1 continua uma ontologia OWL 2 válida, com inferências idênticas em todos os casos práticos (W3C, 2009).

2.5 Transtornos mentais e classificações (ICD e DSM)

A maior parte das desordens médicas são tradicionalmente classificadas utilizando o *International Classification of Diseases (ICD)*, que é o resultado de uma das principais funções da Organização Mundial da Saúde, no qual o ICD é parte de sua constituição e existente desde 1948. O capítulo V do ICD é responsável pela taxonomia de transtornos mentais na 10ª edição do ICD.

Porém, para o caso de transtornos mentais, o ICD divide o espaço na taxonomia de desordens com o *Diagnostic and Statistical Manual of Mental Disorders (DSM)*, publicado pela *American Psychology Association (APA)* desde 1952, mas que só ganhou relevância mundial em sua 3ª edição, e que atualmente está na 5ª edição.

Esta relevância veio devido a introdução de critérios operacionais e definições de desordens menos ambíguas. O objetivo da APA com o lançamento desta 3ª edição foi estabelecer critérios para que quando um paciente fosse avaliado por dois profissionais distintos, a probabilidade de ambos diagnosticarem o mesmo transtorno fosse maior devido a objetividade das classificações.

Em contrapartida, as classificações do ICD não são definidas tão claramente a menos que este critério objetivo seja validado por grupos de pesquisa independentes, baseado em evidências para tal critério. O argumento é que um julgamento clínico de um profissional treinado ainda é superior a critérios não suportados por evidências.

Em geral ambos os modelos de classificação dividem os transtornos nos seguintes subgrupos:

- **Transtornos mentais orgânicos, inclusive os sintomáticos:** Transtornos que tem em comum uma etiologia demonstrável em forma de doença ou lesão cerebral, como por exemplo, a doença de Alzheimer ou a demência vascular;
- **Transtornos mentais e comportamentais devido ao uso de substância psicoativa:** Diferentes transtornos que têm em comum o uso de uma ou mais substâncias psicoativas, por exemplo, transtorno comportamental por abuso de álcool ou opióides;
- **Esquizofrenia, transtornos esquizotípicos e transtornos delirantes:** Transtornos e variações da esquizofrenia em forma aguda ou transitória;
- **Transtornos do humor ou afetivos:** Transtornos nos quais a perturbação fundamental é alteração do humor ou afeto, como por exemplo, transtorno afetivo bipolar ou transtornos depressivos;

- **Transtornos neuróticos, transtornos relacionados com estresse e somatoformes:** Transtornos neuróticos quando não associados com problemas de comportamento em sociedade, ao qual se agrupam as fobias, transtorno obsessivo compulsivo, reações a situações de extremo estresse e transtornos dissociativos, é o caso da agorafobia, da ansiedade generalizada, da amnésia dissociativa e do transtorno hipocondríaco.
- **Síndromes comportamentais associadas a disfunções fisiológicas e fatores físicos:** Grupo de transtornos cujo impacto é uma disfunção fisiológica que não tenha sido classificado em outro grupo, como o caso da bulimia, da insônia não-orgânica e de disfunções sexuais não causadas por transtornos ou doença orgânica¹.
- **Transtornos de personalidade e do comportamento adulto:** Grupo de diversos estados e tipos de comportamento clinicamente significativos, com tendência a persistir e cuja forma é expressa a partir da maneira de viver do indivíduo, bem como seu modo de estabelecer relações consigo e com os outros. Neste grupo estão presentes transtornos de personalidade (paranoica, esquizoide, dissocial), transtornos de hábitos e impulsos (piromania, cleptomania, jogo patológico), transtornos de preferência sexual (exibicionismo, pedofilia).
- **Retardo mental:** Transtornos relacionado com a parada do desenvolvimento ou desenvolvimento incompleto do funcionamento intelectual, caracterizados essencialmente pelo comprometimento durante o período de desenvolvimento dos atributos que determinam o nível global de inteligência, como as funções cognitivas, linguagem, motricidade e comportamento social.
- **Transtornos do desenvolvimento psicológico:** Grupo de transtornos cujo início se situa na primeira ou segunda infância, que incorre no comprometimento ou retardo do desenvolvimento de funções ligadas a maturação biológica do sistema nervoso central e que evoluem sem remissões nem recaídas. A grande maioria das disfunções nesse caso compreendem habilidades linguísticas, espaço-visuais e coordenação motora.
- **Transtornos do comportamento e transtornos emocionais que aparecem habitualmente durante a infância ou a adolescência:** Grupo de transtornos caracterizados pelo início durante a infância ou adolescência, como transtornos hipercinéticos (distúrbios de atividade e atenção), gagueira, transtornos de conduta dissocial, agressiva ou desafiante, e transtornos emocionais com início especificamente na infância.

2.5.1 ICD-11 e web semântica

Construído a partir do predecessor ICD-10, a 11ª versão do *International Classification of Diseases* incorpora as descobertas médicas desde a publicação da 10ª edição em 1992. Mas além de uma simples atualização da taxonomia, a nova edição tem por objetivo estar pronta para uso em *Electronic Health Records* (EHR). Essa necessidade de formalização das

¹ Doença orgânica no contexto de transtornos mentais se refere a transtornos causados por uma condição física ou mudança fisiológica, enquanto transtornos não orgânicos se referem a desordens cuja origem é somente psiquiátrica.

categorias no meio eletrônico fez com que a OMS utilizasse uma plataforma de web semântica colaborativa baseada no Protégé para realizar a modelagem dos conceitos e categorias do ICD-11 utilizando OWL e RDF (TUDORACHE *et al.*, 2010, 2013).

No âmbito dessa tese, a existência de um modelo representando a classificação dos transtornos neuropsiquiátricos mantido pela própria OMS permite gerar um vínculo entre o diagnóstico, os perfis epidemiológicos e a troca de informações com outras plataformas. Essa troca de informação entre plataformas pode seguir uma *língua franca* mantida pelo próprio órgão responsável pela definição das classificações, reduzindo assim a necessidade de mais ontologias para mapear diferentes modelos que existiriam sem essa padronização.

2.6 Reconhecimento de padrões no comportamento humano

Em 2005, Nathan Eagle defendeu sua tese de que, apesar de cada indivíduo ser único e particular, existe um padrão em sua rotina em diferentes escalas, e mesmo que de vez em quando ele mude e faça algo fora do seu padrão, na grande maioria do tempo a estrutura de sua rotina é a mesma (EAGLE, 2005).

Para comprovar isso, Eagle avaliou o uso de modelos de Markov e decidiu pela construção de um modelo chamado de *eigenbehaviors*, cujo objetivo era prover as ferramentas necessárias para construção de modelos do comportamento humano capaz de identificar estruturas que se repetem ao longo do tempo e diferentes escalas temporais: hora, dia, semana, mês, ano. O racional deste modelo é que apesar de muitos comportamentos do ser humano serem identificáveis por modelos de Markov tradicionais, estes não conseguem incorporar padrões temporais em diferentes escalas de tempo (EAGLE; PENTLAND, 2009).

Ao longo da última década, diversos outros trabalhos vêm aplicando técnicas similares para identificação do comportamento humano, dando origem a uma área que vem utilizando a denominação de Ciência social computacional (GILES, 2012).

Nos estudos relacionados a ciência social computacional existe um entendimento que a abundância de informações capturadas pela ubiquidade de dispositivos móveis pode ser utilizada para compreender e melhorar a vida em sociedade, como por exemplo entender as diferenças de desempenho entre times aparentemente semelhantes (DE MONTJOYE *et al.*, 2014), correlacionar traços de personalidade e padrões de comunicação (STOPCZYNSKI *et al.*, 2014), explicar mudanças comportamentais (ALSHAMSI *et al.*, 2015), aplicar novas formas de incentivos utilizando mecanismos sociais (AHARONY *et al.*, 2011) e propor soluções sociais para problemas de saúde em uma comunidade (MADAN *et al.*, 2010).

Nesta tese a identificação e comparação de similaridade nas rotinas do comportamento humano através de históricos de contextos é defendida como a forma apropriada para utilizar o julgamento clínico já aplicado a um indivíduo em tratamento em outros pacientes iniciando o tratamento.

2.6.1 Aplicações do reconhecimento de padrões na saúde mental

A base das pesquisas em ciência social computacional é a capacidade de analisar e de detectar padrões no comportamento humano através de meios computacionais, sendo na

maioria das vezes são utilizados *smartphones* para este fim. É natural que a identificação de padrões no comportamento possa auxiliar no entendimento dos transtornos comportamentais.

Nesta seção são apresentados trabalhos que demonstram as técnicas utilizadas, sendo a maioria destas baseadas na coleta de dados de sensores de dispositivo móvel e na transformação dessas informações em atributos relevantes ao transtorno avaliado, bem como na aplicação de algum algoritmo de aprendizado de máquina para identificação do humor ou transtorno.

Em 2011, Burns et al. desenvolveu um aplicativo para reconhecer o contexto do usuário a fim de identificar variações no humor de pacientes com depressão profunda unipolar e aplicar intervenções *in situ* utilizando conceitos de ativação comportamental, a qual foi uma das primeiras aplicações de *smartphones* para intervenção momentânea com uso de contexto para identificação do humor (BURNS *et al.*, 2011).

Em 2015, Jimenez-Serrano et al. propôs um modelo baseado em redes bayesianas para identificação de depressão pós parto, utilizando dados de sensores de *smartphones* Android (JIMENEZ-SERRANO; TORTAJADA; GARCIA-GOMEZ, 2015).

O'Brien et al. avaliaram se a depressão em idosos estava associada com algum declínio na atividade física a partir do uso de actigrafia, e concluiu que existe uma redução significativa na atividade física em comparação com idosos saudáveis (O'BRIEN *et al.*, 2016).

Faedda et al. avaliaram se utilizando dados de actigrafia poderia diferenciar transtorno bipolar de transtorno de déficit de atenção e hiperatividade em jovens e crianças, e foi capaz de mostrar que existem diferenças no comportamento onde um modelo preditivo de SVM seria capaz de realizar essa distinção com 83% de precisão (FAEDDA *et al.*, 2016).

Abdullah et al. utilizaram smartphones para avaliar a *Social Rhythm Metric* (SRM) em indivíduos com transtorno bipolar e concluíram que a utilização de dados de acelerômetro, microfone, localização e comunicação é uma alternativa viável para monitorar o índice de SRM em pacientes com transtorno bipolar (ABDULLAH *et al.*, 2016; MATTHEWS *et al.*, 2016).

Firth et al mostram que é evidente o crescente interesse nas aplicações de meios computacionais na saúde mental (FIRTH; TOROUS; YUNG, 2016). Porém também é evidente que enquanto os profissionais sejam treinados para diagnosticar, tratar e acompanhar os mais diversos transtornos, todas as aplicações e plataformas se limitam a transtornos específicos. Este problema fica evidente nas comparações e é discutido em mais profundidade no capítulo 3.

2.7 Aprendizado de máquina e classificadores supervisionados

Esta seção aborda oito algoritmos de aprendizado de máquina capazes de realizar classificações supervisionadas que no âmbito do modelo apresentado nesta tese permitem a comparação de uma rotina em relação a outras rotinas conhecidas.

Classificação supervisionada é o processo de definir uma categoria a uma nova amostra baseado nas categorias de observações conhecidas. No processo de classificação supervisionada o algoritmo utilizado é treinado para montar um modelo a partir de uma série de amostras pré-classificadas.

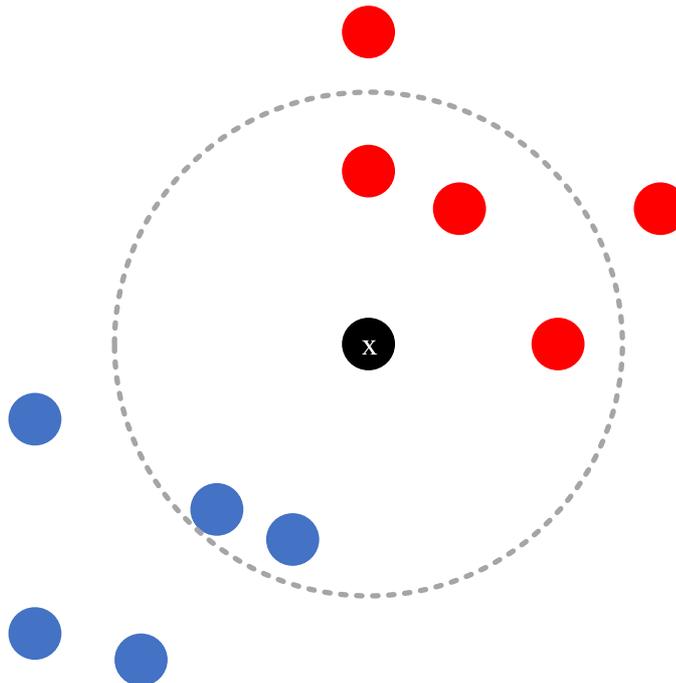
Conforme detalhado no capítulo 4, o modelo Eigenroutine propõe a extração do padrão de comportamento em forma de *eigenbehaviors*, o que implica identificar os padrões ao longo do tempo, reduzindo a amostra à vetores que melhor concentram a informação.

A consequência desta abordagem é que, diferente de trabalhos anteriores que utilizam análise de similaridade em séries temporais, o Eigenroutine abstrai a série temporal e permite a comparação de padrões de comportamento baseado em múltiplos vetores (*eigenbehaviors*) sem vínculos temporais.

Como parte do algoritmo adaptativo de classificação, este trabalho utiliza os seguintes classificadores: *K-nearest neighbors* (k-NN), Máquina de vetores de suporte (SVM), Árvores de decisões e *Random Forests*, Redes neurais *Muti-layer perceptrons*, *AdaBost SAMME*, *Gaussian Naive Bayes* e *Gaussian Process*.

K-nearest neighbors (k-NN) é um algoritmo de classificação onde uma amostra x é classificada baseada na distância de x para as demais observações conhecidas (ALTMAN, 1992). O parâmetro k do k-NN determina quantas observações devem ser utilizadas para determinar a classe de uma amostra x . O cálculo de distância entre a amostra e as demais observações é geralmente realizada utilizando distância euclidiana. A figura 2 ilustra o processo de classificação k-NN com 5 vizinhos, onde neste exemplo a amostra x seria classificada como parte do grupo vermelho.

Figura 2: Processo de classificação com 5 vizinhos



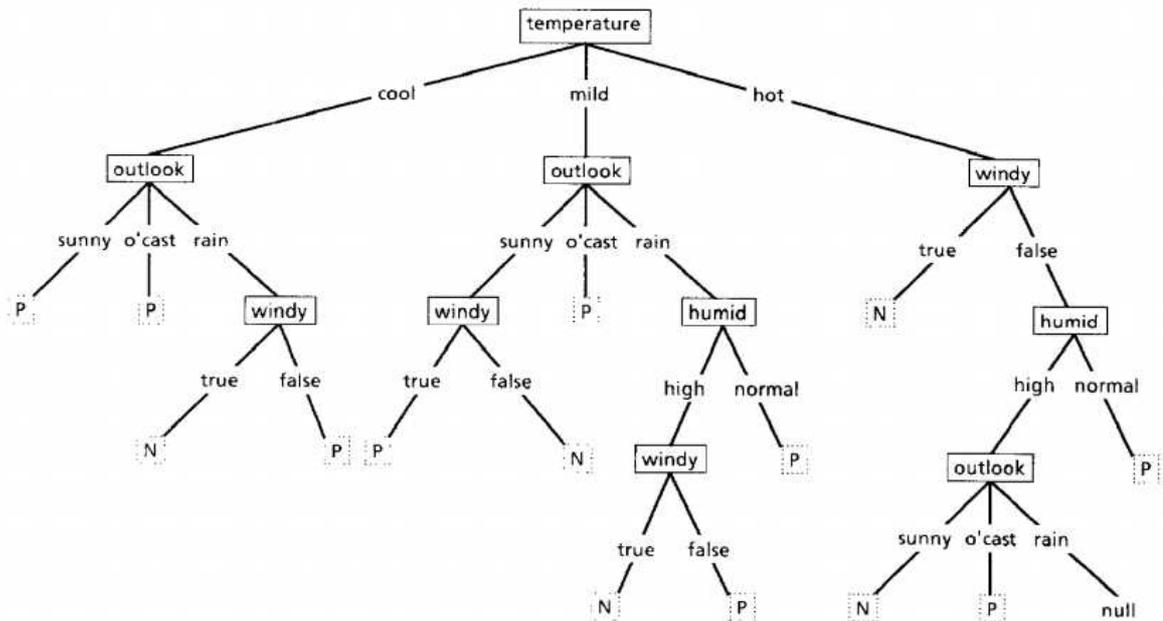
Fonte: Elaborado pelo autor.

Na máquina de vetores de suporte (ou SVM de *Support Vector Machine*) uma amostra é definida como um vetor de n dimensões, e se busca separar as diferentes amostras com $n - 1$ hiperplanos. SVM utiliza uma função *kernel* para realizar mapeamentos não-linear a fim de moldar os dados de entrada para um espaço de características (*feature space*) onde os hiperplanos são construídos (CORTES; VAPNIK, 1995).

Nas árvores de decisão, o algoritmo busca dividir repetidamente as observações conhecidas utilizando uma função para equilibrar a quantidade de informação (entropia) em cada parte da árvore, resultando em uma árvore utilizada para classificar uma nova amostra. A figura 3 ilustra uma árvore de decisão para jogar ou não tênis baseado em atributos como

previsão do tempo, umidade e vento. Complementando as árvores de decisão existe o *Random Forests*, cuja técnica busca criar diversas árvores de decisão para evitar a tendência de sobreajuste do modelo (HAN; KAMBER; PEI, 2012).

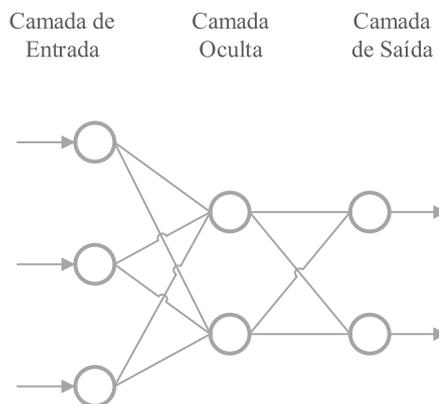
Figura 3: Árvore de decisão para jogar tênis



Fonte: John Ross Quinlan (QUINLAN, 1986).

Redes neurais *Multi-layer perceptrons* (MLP) é uma categoria de redes neurais artificiais com alimentação direta, ou seja, onde os nós das camadas tem sinapses apenas com as camadas do próximo nível. Quando utilizada para classificação supervisionada a rede neural é modelada de forma que cada neurônio de saída represente uma classe distinta a ser classificada pela rede e treinada utilizando retropropagação de erro. A figura 4 apresenta uma rede neural MLP simples, com três neurônios de entrada, dois neurônios na camada oculta, e dois neurônios de saída, que se utilizada para classificação poderiam resultar em duas classes distintas.

Figura 4: Exemplo de rede MLP com três camadas, sendo uma oculta



Fonte: Elaborado pelo autor, baseado em (HAN; KAMBER; PEI, 2012).

Os algoritmos de classificação *Naive Bayes* buscam aplicar o teorema de Bayes com a premissa ingênua (daí o termo *Naive* do nome em inglês) de que todos os atributos utilizados para classificação são estatisticamente independentes. A equação 1 apresenta o teorema de Bayes, ao qual para o *Gaussian Naive Bayes* utiliza a formulação definindo A como as categorias que se deseja classificar, e B como as observações ou amostras de classificação conhecida (HAN; KAMBER; PEI, 2012). O termo gaussiano se utiliza porque se assume uma distribuição normal para os dados. Semelhante em intenção, o processo gaussiano é um método projetado para encontrar aproximações de funções para realizar tanto regressões quanto classificações probabilísticas (RASMUSSEN; WILLIAMS, 2018).

Equação 1: Teorema de Bayes

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)}$$

O classificador AdaBoost SAMME é um algoritmo de aprendizado de máquina meta-heurístico para melhoria de precisão de classificação de outros algoritmos classificadores. AdaBoost inicia o processo realizando o treino baseado no grupo de observações conhecidas e prossegue realizando cópias do modelo inicialmente treinado e realizando novos treinos nestas cópias ajustando os pesos nas observações incorretamente classificadas durante o treino (HASTIE *et al.*, 2009).

2.8 Epidemiologia e transtornos mentais

A epidemiologia é um ramo da medicina que lida com a incidência, distribuição e possível controle de doenças ou fatores que estejam relacionadas à saúde de uma população. Na epidemiologia se estuda quão frequentemente uma determinada doença ocorre em diferentes grupos de pessoas, e busca encontrar o motivo para tal (COGGON; BARKER; ROSE, 2003).

O termo “distribuição” se refere a frequência e padrão de ocorrência dos eventos em uma população, sendo que esse padrão pode variar baseado em tempo (quando os eventos aconteceram), lugar (variações geográficas), ou pessoa (fatores demográficos).

Essas informações epidemiológicas auxiliam o planejamento e avaliação de estratégias de prevenção ou acompanhamento de pessoas onde a doença já tenha se desenvolvido.

Dentro do espectro de estudo da epidemiologia existe um ramo específico para epidemiologia psiquiátrica, cujo objetivo é compreender a ocorrência e distribuição de transtornos mentais e comportamentais em determinados grupos de pessoas, localidades e em determinados pontos do tempo, bem como investigar as causas e consequências desses transtornos com o objetivo de desenvolver estratégias para tratar e prevenir estes transtornos (WEISSMAN, 1987).

Um perfil epidemiológico psiquiátrico é o resultado da união de fatores sociodemográficos e das avaliações clínicas com a intenção de identificar se determinados transtornos tem predomínio em uma população, local, período de tempo, bem como quais os tratamentos adotados, a evolução dos casos e o aumento ou redução de casos ao longo do tempo. Esse perfil é um passo importante para as análises epidemiológicas, pois permite facilitar a identificação de padrões de ocorrência de transtornos.

3 TRABALHOS RELACIONADOS

Uma revisão sistemática foi realizada com o objetivo de entender o estado atual da aplicação de computação móvel e ubíqua no acompanhamento e tratamento de transtornos mentais (BÜTTENBENDER; BARBOSA; MARTINS, 2018).

Uma revisão sistemática é uma forma estruturada e reproduzível de identificação do estado da arte em uma determinada área de conhecimento, utilizada para compreensão dos estudos realizados na área, bem como para descobrir tendências e desafios quanto ao tópico a ser pesquisado. Nove trabalhos relacionados foram selecionados para avaliação devido a relevância ao tema.

3.1 Planejamento da revisão

O principal objetivo da revisão foi determinar como a computação móvel e ubíqua estava sendo utilizada no suporte à saúde mental, e assim entender o estado da arte das aplicações, técnicas e modelos. Sendo assim, as questões de pesquisa da revisão estão listadas na tabela 1.

Tabela 1: Questões de pesquisa para revisão sistemática.

| Referência | Questão de pesquisa |
|-----------------------------|--|
| <i>Questões Gerais</i> | |
| QG1 | Como a computação móvel e ubíqua está sendo utilizada para suportar questões de saúde mental? |
| QG2 | Como dispositivos móveis estão sendo utilizados nesse âmbito? |
| QG3 | Quais transtornos mentais obtiveram sucesso no diagnóstico ou tratamento com o uso da computação móvel e ubíqua? |
| <i>Questões Específicas</i> | |
| QE1 | Quais os transtornos são passíveis de identificação a partir do monitoramento do comportamento? |
| QE2 | Quais intervenções estão sendo realizadas a partir de dispositivos móveis? |

Fonte: Elaborado pelo autor.

A partir das questões gerais e específicas foi possível identificar o foco em saúde (e transtornos) mentais vinculado a aplicação de computação móvel e ubíqua, ao qual a frase geral de busca foi modelada: *computação ubíqua* \wedge *saúde mental*. Desta frase geral se utilizou uma combinação dos termos gerais e de termos específicos a fim de encontrar o maior número possível de trabalhos relacionados. Destes termos, os específicos foram identificados considerando: (a) transtornos com a maior incidência na população, e (b) sinônimos ou

aplicações tecnológicas semelhantes aos termos gerais. A tabela 2 apresenta os detalhes das frases de busca em lógica booleana, que foi traduzida para o formato de cada base de artigos.

Tabela 2: Frases de busca nas bases acadêmicas.

| Termo Geral | Frase de busca |
|-----------------------------|---|
| Computação móvel e ubíqua | (<i>ubiquitous computing</i> ∨ <i>mobile computing</i> ∨ <i>mobile phone</i> ∨ <i>smartphone</i> ∨ <i>smart phone</i> ∨ <i>pervasive computing</i> ∨ <i>Internet of things</i> ∨ <i>IoT</i> ∨ <i>wearable</i> ∨ <i>mHealth</i> ∨ <i>uHealth</i> ∨ <i>mobile health</i>) |
| Saúde e transtornos mentais | ∧ (<i>mental health</i> ∨ <i>mental disorder</i> ∨ <i>depression</i> ∨ <i>depressive</i> ∨ <i>anxiety</i> ∨ <i>bipolar disorder</i> ∨ <i>panic disorder</i> ∨ <i>agoraphobia</i> ∨ <i>psychosis</i> ∨ <i>schizophrenia</i>) |

Fonte: Elaborado pelo autor.

3.2 Bases, estratégia de busca e critérios

A escolha das bases de artigos considerou a característica da frase de busca, facilidades para exportar os resultados e acesso disponível pelo portal de periódicos da CAPES. Para esta revisão foram escolhidas: IEEE Xplore e ACM Digital Library como representantes de trabalhos na área da computação, MEDLINE/PubMed para identificação de trabalhos na área médica e PsycINFO como base de artigos relacionados a psiquiatria e psicologia apresentado na tabela 3.

A busca nas bases se limitou ao título, *abstract* e palavras-chave para trabalhos publicados na última década, conforme apresentado na tabela 3, onde encontra-se o resumo da estratégia.

Tabela 3: Estratégia de busca

| Resumo da estratégia de busca | |
|--------------------------------------|--|
| Bases acadêmicas | <ul style="list-style-type: none"> • ACM Digital Library • IEEE Xplore • MEDLINE/PubMed • PsycINFO • Título |
| Escopo da busca | <ul style="list-style-type: none"> • Abstract • Palavras chave |
| Período de publicação | <ul style="list-style-type: none"> • Novembro de 2006 a Novembro de 2018 |

Fonte: Elaborado pelo autor.

Após as buscas, os seguintes critérios de inclusão foram aplicados: (a) artigos diretamente relacionados à computação e saúde mental, (b) artigos que apliquem alguma forma de computação ubíqua ou dispositivos móveis na solução de um determinado problema relacionado à saúde mental, (c) artigos que façam algum tipo de monitoramento de comportamento, tratamento ou intervenção a partir dos dispositivos e (d) artigos publicados entre novembro de 2006 e novembro de 2016.

E os seguintes critérios de exclusão foram aplicados: (a) artigos que utilizem os dispositivos como meio para aplicação de *surveys* ou questionários, (b) artigos que não foram escritos em inglês e (c) artigos cujo texto completo não estava disponível via portal de periódicos da CAPES.

Tabela 4: Resumo da estratégia de seleção.

| Referência Estratégia de seleção | |
|---|--|
| <i>Crítérios de inclusão</i> | |
| CI1 | Artigo é uma abordagem computacional para saúde mental |
| CI2 | Artigo faz uso de conceitos de computação ubíqua ou faz uso de dispositivos móveis como <i>smartphones</i> ou <i>wearables</i> |
| CI3 | Artigo faz algum tipo de monitoramento do comportamento ou alguma intervenção pelo dispositivo móvel |
| CI4 | Artigo foi publicado entre novembro de 2006 e novembro de 2018 |
| <i>Crítérios de exclusão</i> | |
| CE1 | Artigo faz uso da tecnologia apenas para realização de <i>surveys</i> ou questionários |
| CE2 | Artigo não foi escrito em inglês |
| CE3 | Artigo sem acesso ao texto completo via plataforma de periódicos da CAPES |

Fonte: Elaborado pelo autor.

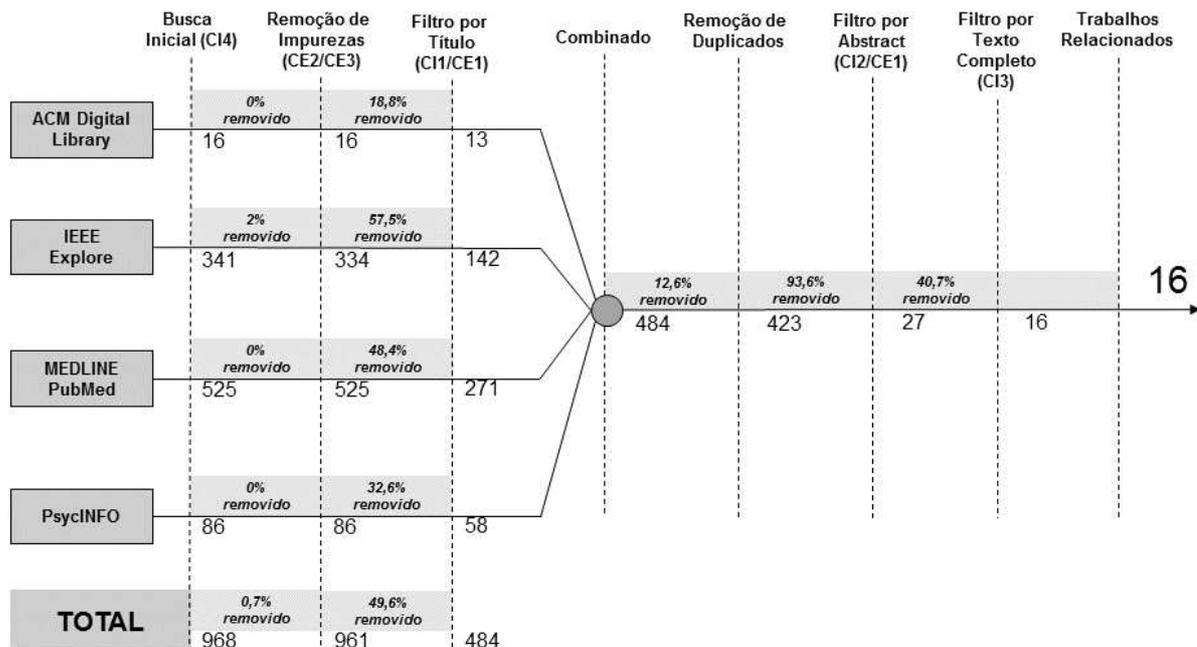
3.3 Resultados da busca

O processo de busca foi composto por seis passos, ilustrados na figura 5. O primeiro passo foi a utilização dos critérios apresentados na tabela 2 para a busca nas quatro bases, onde 968 artigos foram encontrados. O segundo passo foi uma iteração sobre os resultados para remoção de artigos evidentemente irrelevantes ao contexto da busca (resultados em outros idiomas, especificações de radiotransmissores, etc.). O terceiro passo foi o filtro dos artigos cujo título já evidenciava que o artigo estava fora do escopo de trabalhos relacionados a computações móvel e ubíqua aplicados à saúde mental, no qual 484 artigos foram selecionados.

O quarto passo foi a combinação dos resultados e a remoção de artigos duplicados entre bases, ao qual 423 artigos foram selecionados. O quinto passo foi o filtro dos artigos pelo abstract, aplicando um filtro mais detalhado sobre o conteúdo dos artigos para encontrar trabalhos mais próximos a aplicações que sejam capazes de utilizar dispositivos móveis para identificação de transtornos mentais, ou para realização de intervenções, resultado em 27 artigos principais.

O último passo foi a análise do texto completo de trabalhos que apresentem modelos para diagnóstico, tratamento ou acompanhamento de transtornos neuropsiquiátricos utilizando dispositivos móveis ou alguma forma de aplicação de computação ubíqua, resultando em 16 artigos que se resumem em 9 trabalhos relacionados, os quais serão detalhados e comparados nas próximas seções. É importante destacar que a redução de 16 artigos para 9 trabalhos se deve a agregação da análise de diversos artigos de um mesmo grupo de trabalho, principalmente no caso do programa MONARCA e do PSYCHE.

Figura 5: Resumo da seleção



Fonte: Elaborado pelo autor.

3.4 AMoSS

O *Automated Monitoring of Symptom Severity* (AMoSS) foi um estudo realizado pelo Departamento de Psiquiatria da Universidade de Oxford na construção e utilização de um sistema baseado em *smartphones* para monitoramento de sintomas de pacientes em tempo real, com objetivo de alocar recursos psiquiátricos de forma mais eficiente (PALMIUS *et al.*, 2014).

Diferente de outros estudos, o AMoSS foi projetado para acompanhar 130 indivíduos durante 12 meses com o objetivo de compreender melhor o comportamento de indivíduos com transtorno bipolar e transtornos de personalidade e explorar novas formas de monitoramento utilizando dispositivos comerciais e de pesquisa (OSIPOV, 2016).

Este acompanhamento foi realizado em duas etapas. A primeira etapa foi de acompanhamento intensivo, onde sensores para pesquisa eram utilizados pelo paciente por uma semana. Durante esse período, cada paciente foi acompanhado por um acelerômetro GENEActiv, um eletrocardiograma móvel Shimmer, um Proteus patch para medição de ritmo cardíaco e temperatura corporal, e media temperatura e pressão arterial utilizando dispositivos da Omron 3 vezes ao dia.

Durante a fase de acompanhamento prolongado, o mesmo paciente foi então acompanhado com um smartphone Galaxy S3 ou S4, um Fitbit One, um questionário de estado de humor simples por dia e um questionário completo semanal aplicado de acordo com o transtorno previamente diagnosticado.

Osipov conseguiu demonstrar que é possível diferenciar os sintomas de depressão, bipolaridade e transtorno de personalidade utilizando sensores de dispositivos móveis, e propôs um modelo de grupo de sintomas e características que podem ser capturadas por sensores presentes nos dispositivos comerciais como forma de avaliação objetiva de sintomas (OSIPOV, 2016).

Palmius *et al* demonstraram que um questionário simplificado e aplicado com frequência superior aos questionários tradicionais tem precisão equivalente, e poder servir como suporte ao diagnóstico, bem como avaliação do tratamento de distúrbios de humor (PALMIUS *et al.*, 2014).

3.5 FINE

FINE é um aplicativo para plataforma *Android* criado pelo instituto de informática médica da Universidade de Braunschweig baseado na biblioteca *PurpleRobot*. O objetivo desse aplicativo foi identificar indicadores correlacionados a comportamentos de indivíduos com depressão profunda utilizando apenas os sensores dos *smartphones* (DANG *et al.*, 2016).

O FINE analisa dados de acelerômetro utilizando o *Signal Magnitude Area* (SMA) como medida para correlacionar atividades físicas com os dados do sensor, calculadas a cada minuto.

No momento da escrita deste trabalho o FINE ainda estava em fase de avaliação e apenas uma análise preliminar foi publicada. Nesta análise foram apresentados resultados da viabilidade de utilização de um smartphone como complemento de terapia, onde a maioria dos usuários entrevistado utilizaria uma versão mais completa do aplicativo.

3.6 FLATT

O projeto *Fun to Learn to Act and Think through Technology*, conhecido como FLATT tem como parte dos seus estudos a aplicação da terapia cognitivo comportamental a partir de *smartphones* (WATANABE *et al.*, 2015).

Neste trabalho os pesquisadores descreveram um estudo para avaliar se a utilização da terapia cognitivo comportamental (TCC) feita a partir de dispositivos móveis facilitaria a troca de medicação por pacientes diagnosticados com depressão profunda com resistência a farmacoterapia e em fase de transição de medicamentos.

Este aplicativo consiste em oito seções de 30 minutos, mas que levam ao menos 7 semanas para completar devido aos exercícios e aplicações práticas de cada seção. O aplicativo apresenta diálogos entre personagens que explicam os princípios e habilidades que compõem a TCC. Entre cada seção o participante deve completar um exercício prático, aplicando aquilo que foi aprendido. A figura 6 apresenta duas telas do aplicativo de intervenção.

Figura 6: Aplicativo Kokoro do projeto FLATT para intervenção baseada em TCC



Fonte: (WATANABE *et al.*, 2015).

Mantani et al apresentou a estrutura e resultados da avaliação do aplicativo Kokoro onde foram selecionados 164 pacientes dos quais 81 receberam o aplicativo e medicação e 83 pacientes receberam apenas a medicação (MANTANI *et al.*, 2017).

O grupo de pacientes que recebeu o aplicativo e a medicação apresentou em média 2.48 pontos a menos que o grupo de controle no questionário PHQ-9 e 4.2 pontos a menos no questionário BDI-II. Esses benefícios no tratamento se mantiveram por todo período do experimento.

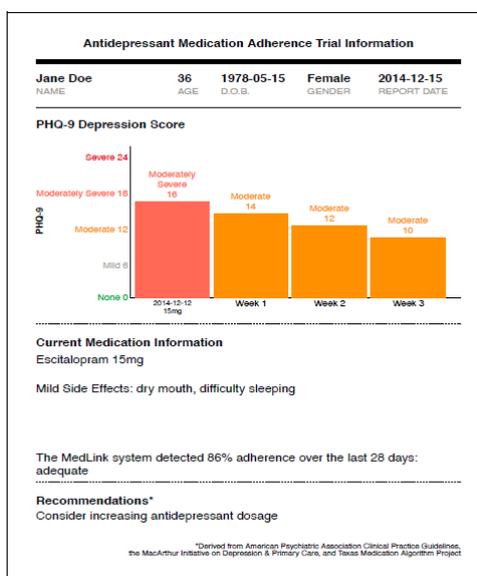
3.7 MedLink

MedLink foi um projeto cujo objetivo era resolver problemas comuns no tratamento de depressão profunda. Neste trabalho os pesquisadores identificaram fatores relacionados ao paciente, principalmente a não aderência a medicação, e fatores relacionados aos profissionais, como dosagem inferior a recomendação, falta de educação do paciente e falta de ajuste na medicação (MOHR *et al.*, 2015).

Neste projeto foi desenvolvido um aplicativo *Android* para apresentar semanalmente conteúdo educativo para o paciente em tratamento, lembrar o paciente quanto à necessidade de uso de medicação usando indicadores do Wisepill case o paciente não tenha administrado a medicação conforme indicação do profissional e realizar questionários com o padrão *Patient Health Questionnaire 8-items* (PHQ-8).

A cada quatro semanas, o MedLink gerava um relatório para o profissional incluindo informações da severidade dos sintomas depressivos (baseados no PHQ-8), efeitos colaterais, taxa de aderência e recomendação de tratamento baseado em diretrizes de saúde pública. Este relatório está ilustrado na figura 7.

Figura 7: Relatório do MedLink para acompanhamento profissional



Fonte: (MOHR *et al.*, 2015).

Os resultados reportados pelo MedLink foram favoráveis, sendo que a aderência a medicação dos pacientes utilizando a plataforma foi alta, com 84% das doses estipuladas sendo administradas e sem nenhuma descontinuidade de tratamento.

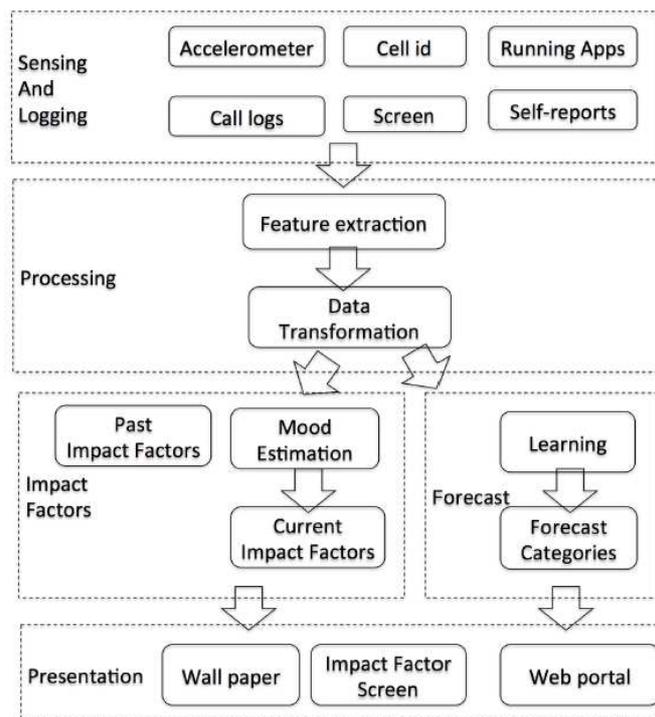
A severidade dos sintomas depressivos também foi significativamente reduzida nos pacientes acompanhados pelo MedLink, e os autores concluíram o trabalho afirmando que o uso sistêmico de soluções móveis para gerenciamento de sintomas depressivos por profissionais de saúde mental traz benefícios ao tratamento.

3.8 MONARCA I e MONARCA II

O projeto MONARCA (*MON*itoring, *treA*tment and *pRediC*tion of *bipolAr* disorder *episodes*) é uma série de experimentos na utilização de *smartphones* como medidas de transtorno bipolar, identificando diferentes indicadores e formas de intervenção e suporte ao profissional de saúde mental (FAURHOLT-JEPSEN *et al.*, 2013, 2014, 2015; MAYORA *et al.*, 2013). Sete publicações relacionadas ao MONARCA foram analisadas durante o processo de revisão sistemática.

Neste projeto foram aplicadas técnicas para identificação do comportamento a partir de atividades físicas (identificadas com indicadores derivados de acelerômetro), mobilidade (identificado a partir do GPS), atividade social (chamadas e trocas de mensagens) e uso em geral do smartphone (tempo em que a tela permaneceu ativa), e questionários próprios do MONARCA para classificação do humor do paciente.

Figura 8: Componentes do MONARCA 2.0 utilizados para construção dos relatórios



Fonte: (FROST *et al.*, 2013).

O uso destes indicadores, conforme apresentado na figura 8, permitia ao aplicativo prover mais conhecimento tanto para o paciente quanto para o profissional de quais atividades melhoravam ou pioravam a apresentação dos sintomas de transtorno bipolar.

Para complementar as intervenções, o aplicativo provia alertas e conteúdo educativo para os pacientes, bem como relatórios e notificações para os profissionais de saúde mental.

Até o momento o MONARCA é o projeto mais completo e abrangente, com contribuições especialmente importantes em relação a indicadores para identificação de transtorno bipolar.

3.9 PSYCHE

PSYCHE (*Personalized monitoring SYstems for Care in mental HEalth*) é o nome de uma plataforma desenvolvida pela Universidade de Pisa para identificar variações de humor em pacientes com transtorno afetivo bipolar baseado em computação ubíqua e tecnologia vestível (VALENZA *et al.*, 2013).

Neste projeto os pesquisadores construíram uma camiseta dotada de sensores biopotenciais para ritmo cardíaco e piezoresistivos para respiração, com bateria de 24 horas de duração e armazenamento de dados em um cartão *microSD*. Esta camiseta, apresentada na figura 9, foi então entregue a três participantes do experimento para utilização no seu dia a dia. A cada 18 horas de uso, os participantes deveriam entregar a camiseta de volta para os pesquisadores para gravar as informações em um banco de dados centralizado.

Durante o experimento, profissionais de saúde mental determinaram o estado de humor de cada paciente baseado em um modelo próprio do PSYCHE com nove estados possíveis, onde os pesquisadores sugeriram duas dimensões entre depressão e mania, ao invés do modelo clássico onde depressão e mania são lados opostos de um mesmo espectro

Figura 9: Tecnologia vestível da plataforma PSYCHE



Fonte: (VALENZA *et al.*, 2013).

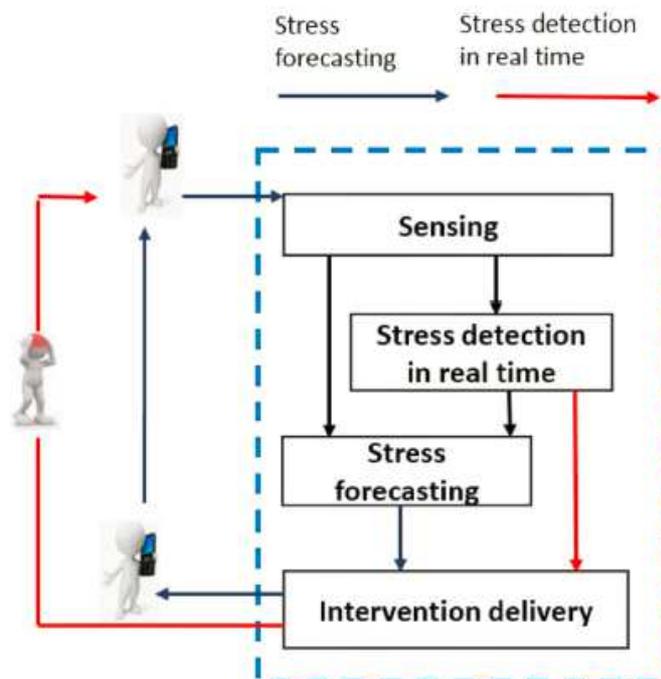
Esta escala foi então utilizada para encontrar indicadores físicos para os estados de humor dos pacientes utilizando uma rede neural *Multi-Layer Perceptron* de 3 camadas, formada por 7 neurônios de entrada, um para cada sinal escolhido para o trabalho, 5 neurônios na camada escondida, e 2 neurônios na camada de saída para os possíveis estados: depressão ou mania.

O PSYCHE demonstrou que existem sinais biológicos para identificação do estado de humor em um paciente com transtorno bipolar com até 95% de precisão, e que a utilização de tecnologia vestível permite identificar tais sinais, com oportunidade de ser utilizado para identificar relapsos.

3.10 PREVENTER

O PREVENTER foi uma série de experimentos e simulações para demonstrar a viabilidade de um sistema de predição de estresse em tempo real e da aplicação de intervenções adaptativas (JAIMES; LLOFRIU; RAIJ, 2016), conforme ilustrado na figura 10.

Figura 10: Fluxo de informações na arquitetura do PREVENTER



Fonte: (JAIMES; LLOFRIU; RAIJ, 2016).

Neste trabalho os autores sugerem um Modelo Oculto de Markov como algoritmo para predição de estresse baseado em sensores físicos a partir de dados de um outro experimento. Neste outro experimento 70 participantes utilizaram um sistema de monitoramento baseado em eletrocardiograma como forma de identificar níveis de estresse, mais especificamente a partir de sinais de variabilidade de ritmo cardíaco (também conhecido pelo nome em inglês *Heart Rate Variability* ou HRV).

No segundo experimento, os autores realizaram uma simulação baseado em um modelo matemático e compararam a utilização do Q-Learning em relação ao algoritmo CALMA como forma de decisão de intervenção em caso de episódios de estresse.

Os resultados dos experimentos demonstraram que com Modelos Ocultos de Markov é possível prever medidas de estresse até 3 minutos antes das alterações e que Q-Learning pode ser utilizado por um sistema para escolha da intervenção em resposta às alterações de humor.

3.11 PRISM

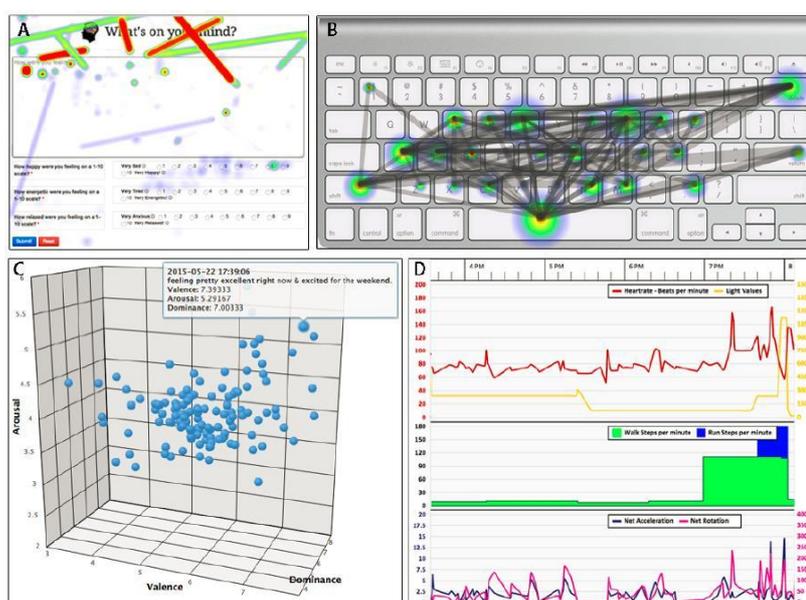
A plataforma PRISM (**P**assive, **R**eal-time **I**nformation for **S**ensing **M**ental Health) é um projeto realizado pelo Programa de Informática Biomédica da Universidade de Stanford (KAMDAR; WU, 2016).

O objetivo desta plataforma é realizar um monitoramento passivo de pacientes para que os mesmos possam entender suas condições de saúde (semelhante ao que o MONARCA sugeriu com *smartphones*), bem como extrair conceitos positivos e negativos para classificar o humor do paciente a partir de um diário virtual.

Um *smartwatch* Samsung Gear S foi utilizado pelos pesquisadores nos experimentos para capturar sinais de: (1) luminosidade de ambiente, (2) ritmo cardíaco, (3) acelerômetro, (4) pedômetro. No diário virtual, os pesquisadores capturaram também os padrões de digitação (velocidade, erros, latência entre teclas) e padrões de interação com o mouse.

Esta plataforma foi então utilizada por 13 participantes saudáveis para avaliação da facilidade de uso da plataforma e das funcionalidades disponíveis. Durante o experimento, tanto os participantes quanto os pesquisadores tinham acesso a uma ferramenta para análise do uso do diário virtual, que apresentava mapas de calor no uso do mouse e teclado, e o uso de palavras no modelo *Valence-Arousal-Dominance* (VAD).

Figura 11: Ferramenta de monitoramento do diário virtual no PRISM



Fonte: (KAMDAR; WU, 2016).

O principal diferencial do PRISM em relação ao demais trabalhos foi a análise de utilização do diário, ilustrado na figura 11, bem como a classificação das palavras no modelo *Valence-Arousal-Dominance* (VAD), e a aplicação de alguns conceitos de privacidade dos dados armazenados.

3.12 SleepSight

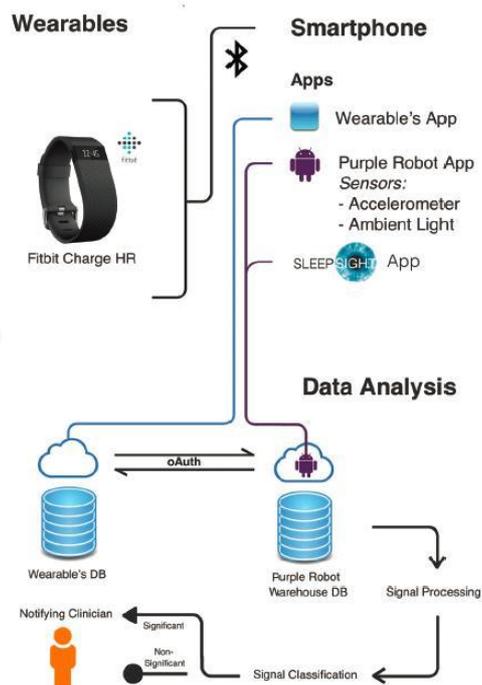
O SleepSight é um sistema para evitar relapsos em pacientes com esquizofrenia ou transtornos esquizoafetivos baseados em dispositivos móveis e tecnologia vestível (KERZ *et al.*, 2016). Neste trabalho os autores apresentaram um modelo e arquitetura e estão realizando um experimento com 16 pacientes diagnosticados com esquizofrenia.

O modelo apresentado pelo SleepSight utiliza uma combinação de sensores de um *wearable* FitBit Charge, sensores de um *smartphone* Nexus 5 e um questionário PANSS (*Positive and negative symptom scale*).

No SleepSight os pesquisadores propõe a captura de dados de acelerômetro, luminosidade do ambiente, e todos os sinais capturados pela biblioteca *PurpleRobot* com o objetivo de realizar uma análise de anomalia para identificar distúrbios psicóticos, e então utilizar essas informações para alertar o profissional de saúde mental. A figura 12 ilustra os componentes da arquitetura do SleepSight.

A análise de anomalia proposta no trabalho, mas ainda não avaliada, é treinar um Processo Gaussiano com um *kernel* periódico utilizando dados dos sensores nos dias em que os sintomas do paciente apresentam um comportamento de remissão da psicose.

Figura 12: Arquitetura e dispositivos do SleepSight



Fonte: (KERZ *et al.*, 2016).

O estudo ainda está em andamento e a metodologia de detecção de anomalia ainda está sendo construída, o que levou os autores a optarem por não realizar nenhuma análise preliminar dos dados coletados até agora.

3.13 Comparativo

O comparativo apresentado nesta seção foi subdividido em três tabelas comparativas. A primeira tabela é uma comparação geral sobre funcionalidades gerais que cada trabalho aborda. A segunda tabela é uma comparação focada em dispositivos, algoritmos e indicadores apenas dos trabalhos que utilizaram dispositivos de suporte ou aplicaram algum algoritmo de classificação. A terceira tabela é a comparação de trabalhos que tenham realizado alguma intervenção, identificar qual tipo de intervenção foi utilizada e quais de ferramentas de suporte ao profissional de saúde mental foram disponibilizadas.

A primeira comparação apresentada na tabela 5 aborda cinco categorias principais:

- **Transtorno:** Qual transtorno mental abordado pelo trabalho;
- **Wearable ou suporte:** Se o trabalho utilizou ou tem a intenção de utilizar algum outro dispositivo de suporte, seja *smartwatch* (p. ex. Samsung Gear), um *fitness tracker* (p. ex. FitBit Charge), *wearable* não comercial ou uma caixa de remédios inteligente (p. ex. Wisepill);
- **Actigrafia:** Se o trabalho utilizou ou tem a intenção de capturar as atividades do paciente para utilizar em seu modelo de alguma forma;
- **Intervenção:** Se o trabalho realizou ou tem a intenção de realizar alguma intervenção automatizada ou prescrita, a partir do dispositivo móvel ou de algum dispositivo que o paciente carregue consigo no dia-a-dia;
- **Profissional:** Se o trabalho incluiu profissionais de saúde mental em seu modelo, e se o trabalho de alguma forma suporta o trabalho do profissional a fim de tornar o mesmo mais eficiente.

Epidemiologia não foi considerado como critério geral uma vez que nenhum trabalho mencionou nos resultados ou nos modelos a possibilidade do uso das informações capturadas na construção de perfis epidemiológicos, ou qualquer menção a epidemiologia psiquiátrica.

Uma observação de destaque da comparação apresentada na tabela 5 é o fato que a maior parte dos trabalhos não consideram o profissional da saúde como parte do processo de tratamento em seus respectivos modelos. Esses trabalhos, com exceção do MedLink e MONARCA, focaram na tentativa de identificar ou intervir nos distúrbios sem consultar ou informar o profissional, nem utilizando a opinião clínica como subsídio para alimentar algoritmos para identificação de transtornos.

Outra observação é o foco da maioria dos trabalhos em transtornos específicos, onde somente o PRISM propôs uma abordagem genérica, enquanto o AMoSS abordou três transtornos com o objetivo de comparar a diferença no comportamento buscando identificar o melhor algoritmo para classificação do transtorno.

Tabela 5: Comparativo geral entre os trabalhos relacionados.

| Trabalho | Transtorno | Wearable / Suporte | Actigrafia / Sensores | Intervenção | Profissional |
|------------|---|--------------------|-----------------------|-------------|--------------|
| AMoSS | Depressão, Bipolaridade e Personalidade | ● | ● | | |
| FINE | Depressão profunda | | ● | | |
| FLATT | Depressão profunda | | | ● | |
| MedLink | Esquizofrenia | ● | | ● | ● |
| MONARCA | Bipolar | | ● | ● | ● |
| PREVENTER | Estresse crônico | ● | ● | ● | |
| PRISM | Transtornos em Geral | ● | ● | | ● |
| PSYCHE | Bipolar | ● | ● | | |
| SleepSight | Esquizofrenia | ● | ● | | ● |

Fonte: Elaborado pelo autor.

O segundo comparativo, apresentado na tabela 6, compara os diferentes dispositivos utilizados em conjunto com o *smartphone*, onde é possível observar a vasta gama de dispositivos e técnicas utilizadas para classificação de indivíduos com transtornos neuropsiquiátricos. A tendência mais evidente neste comparativo é o uso de relógios inteligentes para auxiliar o *smartphone* na identificação de transtornos neuropsiquiátricos, possivelmente devido à disponibilidade comercial e ao fato de coletarem dados de atividades e ritmo cardíaco. Em termos de algoritmos e indicadores, não existe um padrão definido, e em geral cada trabalho definiu sua própria forma de segmentação de atividades e escolheu os indicadores que melhor representaram o transtorno avaliado.

Tabela 6: Comparação de dispositivos, algoritmos e indicadores

| Trabalho | Dispositivos utilizados | Algoritmos de Classificação | Indicadores para Classificação |
|------------|---|---|--|
| AMoSS | GENEActiv, FitBit, ECG Shimmer, Proteus | Regressão Logística e SVM | Indicador baseado na segmentação de atividades definido pelos autores |
| MedLink | Wisepill | Não utilizou nenhum | Não utilizou nenhum |
| MONARCA | Somente o smartphone (HTC Desire S) | KNN e SVM | Indicador baseado em atividade social (chamadas), atividade física, mobilidade e uso do smartphone, definido pelos autores |
| PREVENTER | Eletrocardiograma | Modelo Oculto de Markov | Indicador baseado na variabilidade do ritmo cardíaco |
| PRISM | Samsung Gear S | <i>Random Forest</i> , SVM, KNN e <i>Gradient Booster</i> | Indicador baseado em ritmo cardíaco, intensidade de luz, acelerômetro e pedômetro |
| PSYCHE | Camiseta com sensores cardíacos e de respiração | <i>Multi-layer perceptron</i> de 3 camadas | Indicadores específicos baseados em respiração e intervalo de batimento cardíaco, definido pelos autores |
| SleepSight | FitBit Charge HR | Detecção de anomalia via processo Gaussiano | Indicadores baseados em acelerômetro, iluminação e questionário de humor |

Fonte: Elaborado pelo autor.

O terceiro comparativo, apresentado na tabela 7, lista os trabalhos que realizaram alguma intervenção, qual o tipo de intervenção realizada, e quais ferramentas de suporte ao profissional de saúde mental que foram disponibilizadas.

Tabela 7: Comparação de tipo de intervenções e suporte ao profissional

| Trabalho | Tipo de Intervenção | Suporte ao Profissional |
|------------|--|--|
| FLATT | Terapia Cognitivo Comportamental | Nenhum |
| MedLink | Conteúdo Educacional e Alerta de Medicação | Suporte ao tratamento com <i>Wagner Chronic Care Model</i> . Informações sobre aderência a medicação e evolução do paciente medido via PHQ-8 |
| MONARCA | Conteúdo Educacional e Alertas de potencial remissão | Relatórios quanto às respostas dos questionários e alertas de potencial remissão |
| PREVENTER | Parte do modelo é uma seleção adaptativa de intervenção com Q-Learning. Não menciona uma técnica específica. | Nenhum |
| PRISM | Nenhum | Relatório com indicadores de atividade física |
| SleepSight | Nenhum | Notificações em caso de anomalia detectada nas atividades físicas |

Fonte: Elaborado pelo autor.

Considerando o resultado dos três comparativos, este trabalho se diferencia dos demais trabalhos por quatro motivos: (1) o entendimento que a manifestação do transtorno é particular ao indivíduo, mas que indicadores comuns podem ser usados para comparação, (2) o entendimento que o profissional de saúde mental é uma peça chave que deve fazer parte do processo não só como consumidor de informação, mas como fonte de diagnóstico e intervenções, (3) que a fragmentação de abordagens é prejudicial, uma vez que o profissional de saúde mental deve ser capaz de atender e diferenciar os mais diversos transtornos e (4) que o diagnóstico clínico em uma plataforma integrada aliado a informações de comportamento capturado por dispositivos móveis pode ser utilizada para a construção de um melhor entendimento da epidemiologia psiquiátrica.

Estes diferenciais estão diretamente relacionados às questões de pesquisa da seção 1.2 e aqui replicadas:

1. “Como deve ser um modelo computacional para **identificar padrões comportamentais** em indivíduos com transtornos neuropsiquiátricos a partir do histórico de contextos de forma a **suportar o tratamento e acompanhamento** de outros indivíduos? ”

2. “É possível utilizar esse modelo de auxílio de indivíduo para **identificação automática de perfis epidemiológicos** de transtornos neuropsiquiátricos?”

O primeiro diferencial remonta a vantagem na utilização de históricos de contextos de diversos indivíduos como forma de diagnosticar outros indivíduos. A abordagem dos trabalhos relacionados no diagnóstico foi de capturar informações dos sensores, definir indicadores baseados nos dados de sensores que representassem alguma mudança no comportamento para o transtorno que estava em estudo e comparar diferentes indicadores para encontrar aquele que melhor classificasse o transtorno. O que este modelo defende é que o uso desses indicadores seja baseado em históricos de contextos para que a identificação de um transtorno seja de fato baseada em outro indivíduo já clinicamente diagnosticado. A vantagem sobre um modelo genérico é que a manifestação dos transtornos no comportamento tende a ser individual, e a variação da intensidade dessa manifestação tornaria um modelo genérico menos preciso.

O segundo diferencial está relacionado a trazer benefícios ao profissional de saúde mental. Nenhum dos trabalhos que utilizam alguma forma de computação móvel para diagnóstico ou intervenções consideraram o julgamento clínico como parte de seu modelo, focando apenas nos questionários objetivos, que por mais que sejam aceitos como guias, não substituem a necessidade do profissional para o diagnóstico. Além disso, a existência de uma plataforma para gerenciamento de transtornos neuropsiquiátricos abre novas formas de acompanhamento de intervenção, permitindo aos profissionais acompanharem o andamento do tratamento de forma a não depender apenas de informações subjetivas, e de definir intervenções ecológicas como suporte ao tratamento.

O terceiro diferencial é a conexão entre o profissional e a epidemiologia. Na grande maioria dos trabalhos relacionados os modelos focaram no diagnóstico de um transtorno específico, e são de suma importância para evolução do estado da arte no diagnóstico de transtornos mentais. Porém, este trabalho defende que a aplicação dessa evolução computacional deve ser em uma plataforma única, e não fragmentada, uma vez que o profissional de saúde mental deve diagnosticar e tratar os mais diversos transtornos, e quanto mais transtornos na mesma plataforma, maior a capacidade da mesma em coletar dados e diferenciar estes transtornos.

O quarto diferencial é a necessidade de compreender melhor os fatores determinantes dos transtornos mentais. Conforme destacado no início desta seção, nenhum trabalho analisado abordou ou mencionou a possibilidade do uso destas informações para contribuir para a epidemiologia psiquiátrica dos transtornos avaliados. Neste trabalho, o conhecimento sobre as manifestações dos transtornos é reforçado pelo uso da plataforma e utilizado para contribuir no diagnóstico de novos pacientes. Uma vez que os perfis epidemiológicos sejam identificados, estes poderiam ser utilizados para guiar políticas de saúde pública, reduzindo assim o impacto dos transtornos na sociedade.

4 MODELO EIGENROUTINES

Este capítulo apresenta o Eigenroutines², modelo computacional cuja capacidade é extrair e comparar rotinas comportamentais a partir do monitoramento contínuo de indivíduos com transtornos neuropsiquiátricos.

As seções 4.1, 4.2, 4.3 e 4.4 apresentam o modelo conceitual com os elementos necessários para realização do monitoramento contínuo, extração de histórico de contextos, a identificação e comparação de rotinas, e um fluxo do processo no modelo explicando como cada passo está conectado a um conceito básico. Estes elementos foram definidos a partir da revisão de literatura apresentado no capítulo 3.

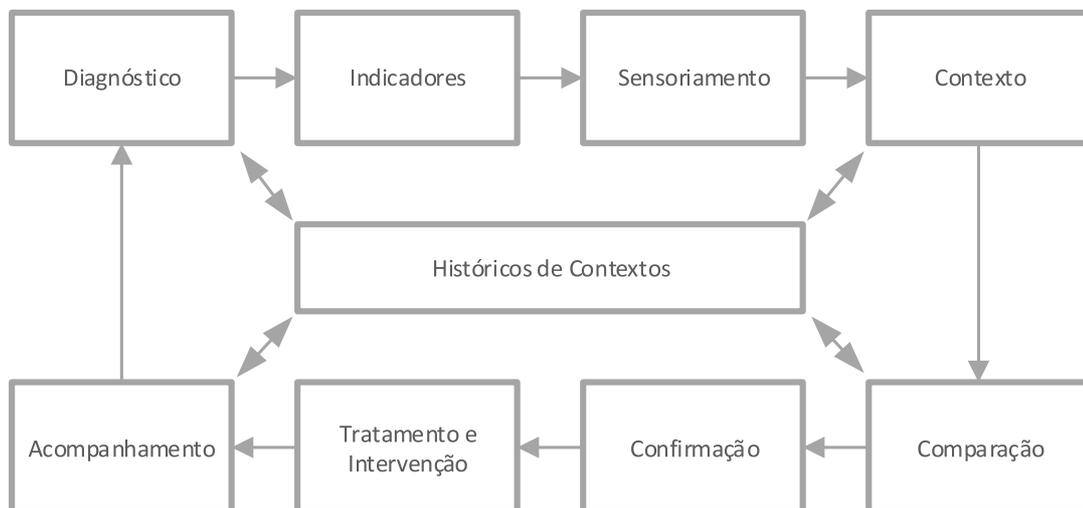
A seção 4.5 apresenta um novo algoritmo de extração e comparação de rotinas comportamentais em histórico de contextos. A seção 4.6 apresenta um cenário de exemplo ilustrando os conceitos apresentados nas seções anteriores.

As seções 4.7 e 4.8 apresentam a arquitetura e os componentes de software genéricos para implementação dos elementos apresentados nas seções do modelo conceitual.

4.1 Conceitos básicos

O Eigenroutines é composto por nove conceitos, ilustrados na figura 13. Oito conceitos formam um fluxo contínuo de troca de informação, enquanto o conceito de históricos de contextos é representado como uma figura central, que permeia e interage com os demais.

Figura 13: Fluxo de informação entre os conceitos



Fonte: Elaborado pelo autor.

² Em álgebra linear, Autovetores e autovalores (*Eigenvectors* e *eigenvalues*) resultam da operação de decomposição espectral de matrizes e representam a essência, ou as partes constituintes, da matriz original. O nome Eigenroutines deriva da noção que o modelo é capaz de extrair a essência das rotinas comportamentais, ao mesmo tempo em que utiliza a decomposição espectral para atingir estes resultados, conforme explicado na seção 4.5.

O conceito de **Diagnóstico** representa a interação entre profissional e paciente com o resultado de diagnosticar o transtorno a partir de um julgamento clínico. Neste modelo, o primeiro diagnóstico será resultado apenas do julgamento clínico, enquanto os diagnósticos subsequentes serão suportados por informações do comportamento do paciente, e como a variação de seu comportamento se compara com outros indivíduos com transtornos mentais semelhantes. O conceito de diagnóstico por julgamento clínico serve também para identificação de comorbidades, que por sua vez auxiliam a determinar os indicadores mais apropriados e para validar o diagnóstico nos encontros subsequentes.

Os **Indicadores** são definidos como o estado de um indivíduo em uma determinada janela de tempo e cuja variação pode caracterizar um transtorno, e em sua grande maioria são conhecidos na literatura médica como biomarcadores. Por exemplo, se um paciente é diagnosticado com transtorno afetivo bipolar, indicadores identificados por Osipov podem ser utilizados para comparar a rotina desse paciente com outros indivíduos com diagnóstico confirmado de bipolaridade (OSIPOV, 2016). Osipov identificou como sinais de determinadas atividades físicas se relacionam com dimensões de sintomas de transtornos neuropsiquiátricos, conforme identificados por Peter Liddle (LIDDLE, 2001). Nos indicadores de Osipov, transtornos na dimensão de humor de Liddle podem ser parcialmente identificados por uma variação significativa na necessidade de sono, que por sua vez podem ser detectados pelo tempo que um determinado indivíduo passa deitado e o tempo que passa dormindo.

O **Sensoriamento** é o resultado da definição dos indicadores. Cada indicador está vinculado a características que podem ser identificadas ao longo do tempo por movimentação, atividade social, luminosidade, localização, ou questionando o próprio paciente sobre seu estado e sintomas. Todas essas características são representadas por um ou mais sensores, dados de utilização ou questionários existentes no *smartphone* ou *wearable*. O objetivo do sensoriamento é captar os dados em sua forma mais rudimentar para permitir o reuso da informação em diferentes tipos de indicadores. Neste trabalho o sensoriamento é classificado em duas formas: (1) sensoriamento passivo, onde sensores existentes em *smartphones* ou *wearables*, bem como informações de utilização de aplicativos e de aderência a intervenções, são utilizados de forma a não necessitar da atenção do paciente para realizar as medições, e (2) sensoriamento ativo, onde existe a necessidade de interação com o paciente para determinar propriamente o seu estado, geralmente realizado através de questionários curtos ou jogos, apresentados uma ou mais vezes ao dia para o paciente.

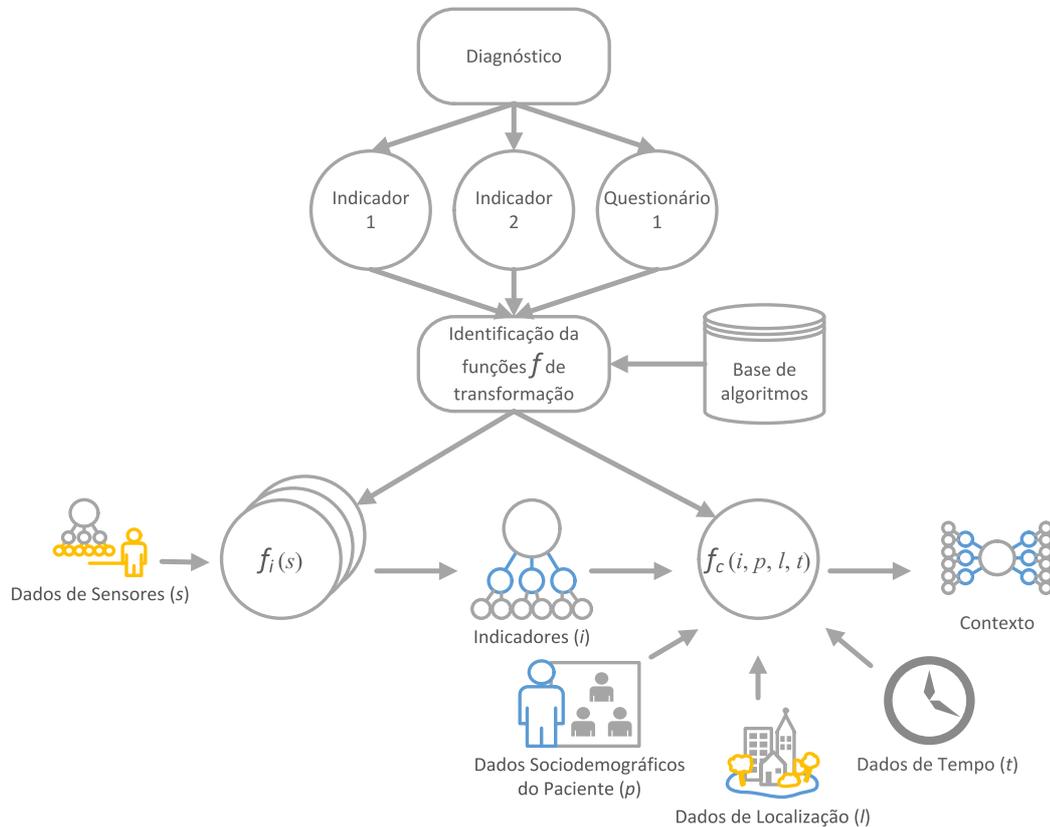
O **Contexto** é a transformação dos dados de sensores em indicadores, dispostos com a informação de localização, tempo e sociodemográfico do paciente. É importante ressaltar que o contexto é modelado por transtorno ou por comorbidade. Isso significa que vários contextos podem ser construídos para um mesmo paciente em uma mesma janela de tempo, e cada um deles pode representar a apresentação de sintomas de um (ou mais) transtornos diagnosticados ou das comorbidades identificadas pelo modelo. Devido a essa característica de múltiplos contextos, existe a necessidade de utilizar diferentes algoritmos de transformação, adaptados de acordo com o diagnóstico, conforme ilustrado pela figura 14.

A figura 14 apresenta a entrada de dados de sensores que passa por uma função $f_i(s)$ de transformação de sensores s em indicadores i . Essa função é determinada pela própria característica dos indicadores derivados do diagnóstico.

Ou seja, o indicador determina quais sensores serão utilizados, e como esses dados dos sensores são transformados em dados de indicadores. Uma vez que os dados tenham sido transformados em indicadores, outra função $f_c(i, p, l, t)$ recebe indicadores i , perfil do paciente p , dados de localização l e dados de tempo t para construir o contexto c . Essa função também

é adaptativa uma vez que a forma de representação dos indicadores no contexto pode variar com a evolução do estado da arte na identificação de comportamento a partir de dispositivos móveis.

Figura 14: Relação entre diagnóstico, sensoriamento e contexto.



Fonte: Elaborado pelo autor.

Os **Históricos de contextos** são a representação de uma série de contextos ao longo do tempo, onde rotinas são representadas como uma janela de *eigenroutines*. A função dos *eigenroutines* é extrair a rotina de um indivíduo baseado nos indicadores, e dessa rotina comparar as variações com outros indivíduos em diferentes estágios de tratamento.

O conceito de **Comparação** de históricos de contextos no modelo é definido como a distância da rotina de comportamento do paciente em relação ao comportamento de outros indivíduos com diagnóstico clinicamente confirmado utilizando uma seleção adaptativa de algoritmos de análise de similaridade. A função da comparação é identificar se o comportamento do paciente em questão está similar ao comportamento de outros indivíduos do modelo, e dentro dos parâmetros do que representam os transtornos previamente diagnosticados.

A **Confirmação** do diagnóstico se repete ao longo dos encontros, onde o profissional de saúde mental ajusta ou confirma o diagnóstico anterior baseado no comportamento do indivíduo, bem como define dentro do seu entendimento o estágio e a severidade do transtorno em questão. A importância da confirmação no modelo é devido ao reforço do entendimento do comportamento de um indivíduo como marcador. Esse marcador auxilia o modelo a diagnosticar outros indivíduos no futuro e a construir o perfil epidemiológico baseado nos grupos de comportamento comum a um determinado transtorno.

O conceito de **Tratamento e Intervenção** ecológica é a aplicação de ferramentas, conteúdo, lembretes e interações com o paciente, onde o objetivo é conseguir reduzir ou eliminar os sintomas do transtorno diagnosticado durante o dia-a-dia do paciente. Uma intervenção ecológica pode ser um conteúdo educacional exibido de acordo com um cronograma definido pelo profissional, um lembrete de medicação, exercícios de respiração e meditação conforme agendamento ou agravamento de sintomas, já que a intervenção pode ter acesso aos sensores, indicadores e contexto, e podem atuar baseado nestas informações. Uma intervenção é uma aplicação a parte, e é sugerida pelo modelo ao profissional, que pode adicionar ou remover intervenções conforme a necessidade do paciente.

O **Acompanhamento** se caracteriza pelo relatório das atividades e comportamento do indivíduo para o profissional e por alertas em casos de remissão. É um resumo dos indicadores, dos diagnósticos baseado em históricos de contextos, e a comparação do mesmo com outros indivíduos em tratamento e seus respectivos estágios. O acompanhamento serve como ferramenta para o profissional entender a evolução do caso, a aderência às intervenções prescritas, e a eficiência destas intervenções em relação a outros casos. Este é o passo final do ciclo, que pode ser continuado com um novo diagnóstico, com a determinação da remissão ou cura. Esta fase é contínua, e enquanto o paciente estiver envolvido com a plataforma será constantemente acompanhado.

4.2 Separação entre sensoriamento e contexto

No Eigenroutines todo contexto é formado por indicadores, enquanto informações de sensores são armazenadas separadamente do contexto. Todo indicador é computado a partir de dados de sensores de dispositivos móveis inteligentes e resulta em uma variável discreta ou em uma informação contínua.

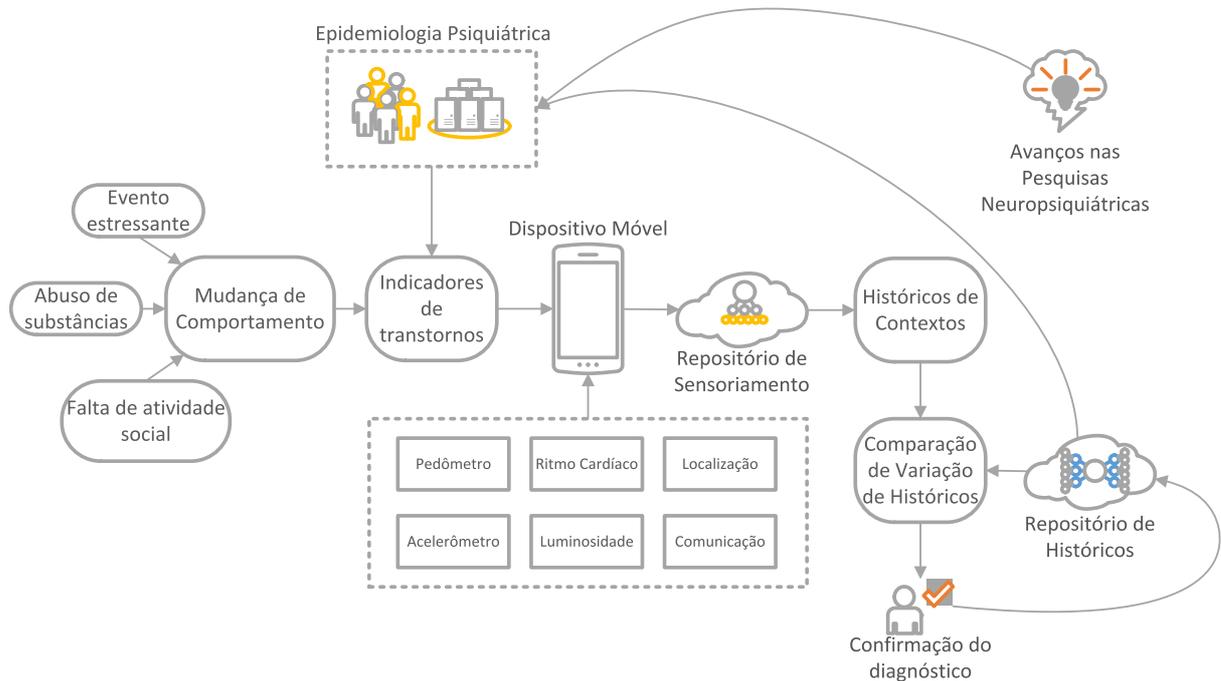
Em outras palavras, um indicador é um estado computado a partir de um sensor conhecido onde o algoritmo utilizado para definir este estado pode ser implementada de forma a suportar diferentes dispositivos e sensores.

Um exemplo de indicador é a “intensidade de atividade”, que quando definida de forma contínua representa quantos minutos em uma determinada janela de tempo o usuário se manteve ativo. Outro exemplo de indicador é a necessidade de sono de um paciente, que quando definida de forma discreta pode ser representada como baixo (inferior a 7 horas), normal (7 a 9 horas) ou alta (mais de 9 horas). Neste exemplo ambos indicadores podem ser calculados com base em um actígrafo, ou seja, um mesmo sensor é capaz de produzir diferentes informações relevantes para identificação de transtornos neuropsiquiátricos.

Assim como um mesmo sensor pode ser utilizado por diversos indicadores, também é possível que novos indicadores sejam descobertos por avanços científicos e modelados como formas mais precisas de identificar transtornos neuropsiquiátricos.

A figura 15 ilustra o modelo por uma perspectiva de mudança comportamental e sensoriamento passivo, e apresenta o aspecto de separação dos repositórios de sensoriamento e contexto.

Figura 15: Relação entre epidemiologia, indicadores e sensoriamento passivo no modelo



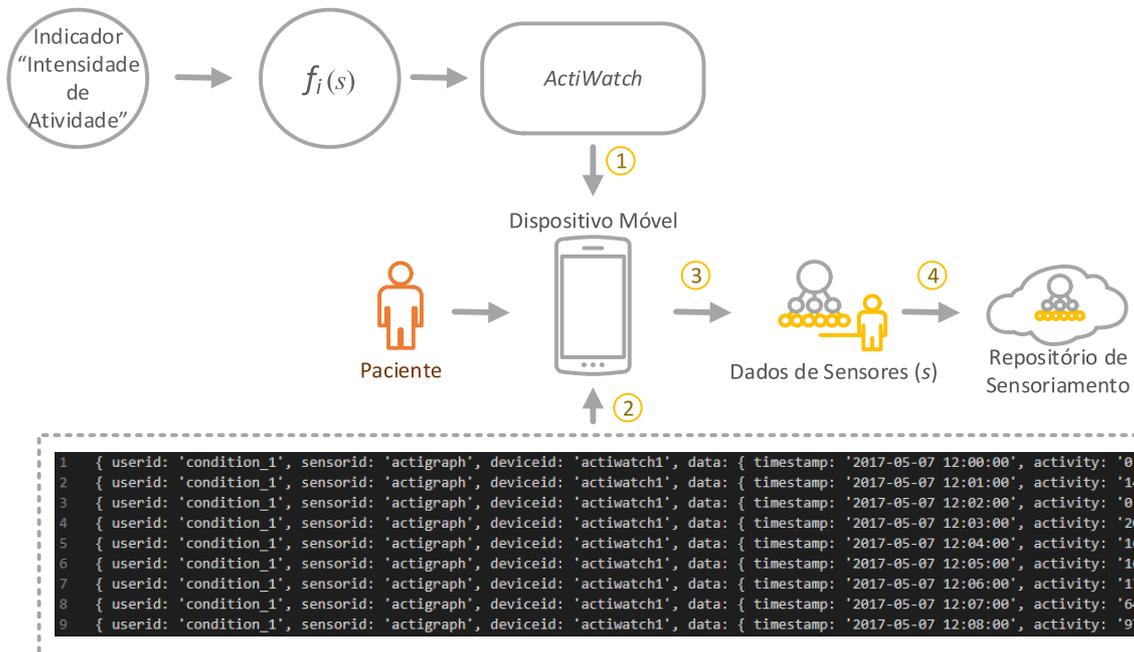
Fonte: Elaborado pelo autor.

Considerando um paciente já diagnosticado, é de se esperar uma anomalia comportamental causada pelo transtorno. O conhecimento do que se espera dessa anomalia vem de um repositório, representado na figura pela epidemiologia psiquiátrica, construído a partir dos históricos de contextos e da evolução da pesquisa quanto à identificação de indicadores comportamentais que caracterizem os transtornos.

Uma vez que os indicadores são identificados, o dispositivo móvel fica responsável por realizar o sensoriamento passivo que por sua vez é armazenado num repositório de sensoriamento, onde esse repositório é um aspecto do conceito de sensoriamento, onde os dados dos sensores são armazenados em sua forma original.

A figura 16 ilustra um paciente ao qual o indicador “Intensidade de Atividade” fora selecionado, e cujo resultado da função de transformação de indicadores em sensores $f_s(i)$ determinou a possibilidade de sensoriamento via actigrafia com o uso do dispositivo ActiWatch como recurso de sensoriamento. Esta determinação é enviada ao dispositivo móvel (item 1 da figura), que armazena os dados de sensoriamento (item 2 da figura) em sua forma original no repositório de sensoriamento (itens 3 e 4 da figura).

Figura 16: Paciente monitorado com ActiWatch e dados de sensoriamento



Fonte: Elaborado pelo autor.

Com o recente interesse acadêmico em relação à classificação do comportamento humano é natural que os indicadores e algoritmos evoluam ao longo do tempo. Portanto, essa separação permite a reconstrução dos históricos, tanto de indivíduos que já passaram por tratamento quanto de indivíduos em tratamento, e a comparação da variação de seus comportamentos em novos indicadores que sejam comprovadamente mais precisos na identificação de transtornos. Essa separação permite também a comparação de diferentes estratégias em relação ao diagnóstico clínico, para que os indicadores com maior precisão em relação ao diagnóstico clínico sejam recomendados aos profissionais.

4.3 Perfis epidemiológicos

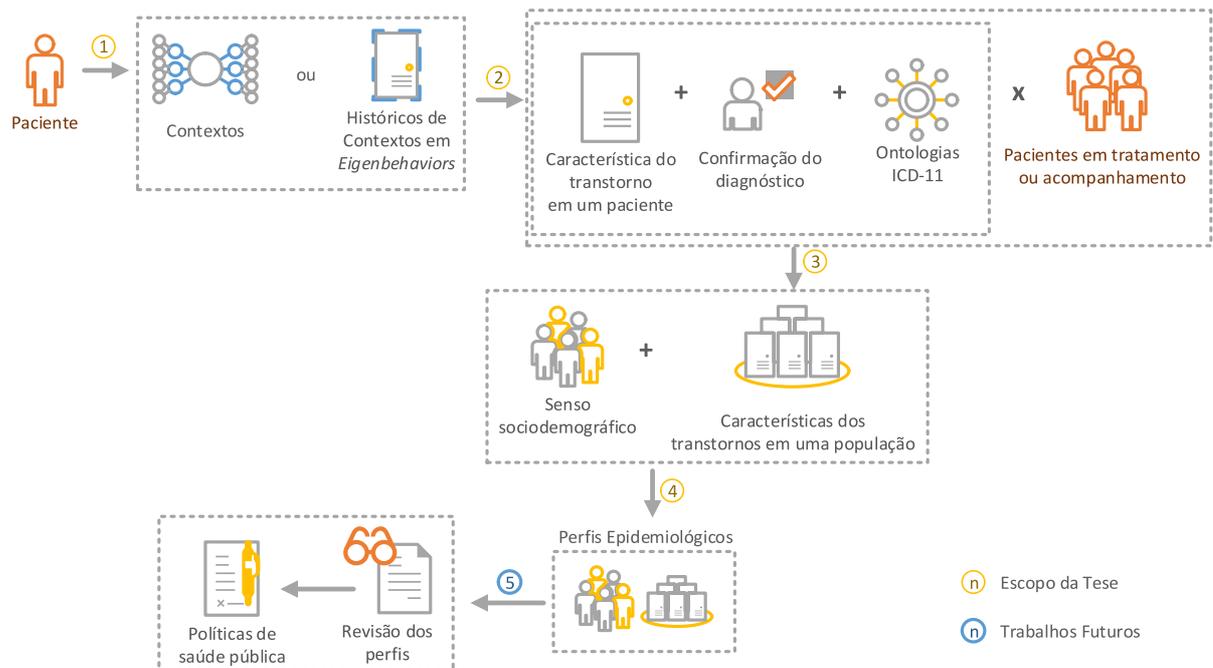
Uma vez o modelo estando aplicado em um sistema e em uso por uma parcela de profissionais e população em tratamento, seria possível identificar os perfis epidemiológicos dos transtornos utilizando a massa de dados disponível na plataforma. A figura 17 apresenta os conceitos e etapas envolvidas na construção dos perfis.

A **primeira etapa** é a aquisição das informações de pacientes em forma de contextos. No processo ilustrado pela figura 13 o conceito de diagnóstico é responsável para aquisição de informações sociodemográficas de um paciente, representado pelo evento de avaliação médica apresentado na ontologia de seção 4.8. Essa avaliação médica pode determinar o diagnóstico como preliminar, confirmado ou em remissão, e pode conter um ou mais transtornos identificados pelo conceito de diagnóstico.

A **segunda etapa** é a conversão do contexto em características do transtorno em um determinado paciente. Essas características são então categorizadas utilizando referência à ontologia da ICD-11 a partir da confirmação do diagnóstico pelo profissional de saúde mental. Esta etapa está relacionada ao conceito básico de confirmação, cujo impacto é criar uma nova instância de avaliação médica confirmando o diagnóstico de um ou mais transtornos.

A **terceira etapa** se inicia com um número suficiente de pacientes em tratamento, acompanhamento ou já tratados na plataforma e com as características propriamente classificadas utilizando a ontologia para classificações de doenças oficialmente publicadas pela OMS. Nesta etapa se agregam as informações sociodemográficas e características como a incidência e remissão, onde com essas informações disponíveis já seria possível realizar a identificação da relações entre transtornos e características sociodemográficas.

Figura 17: Processo de construção dos perfis epidemiológicos



Fonte: Elaborado pelo autor.

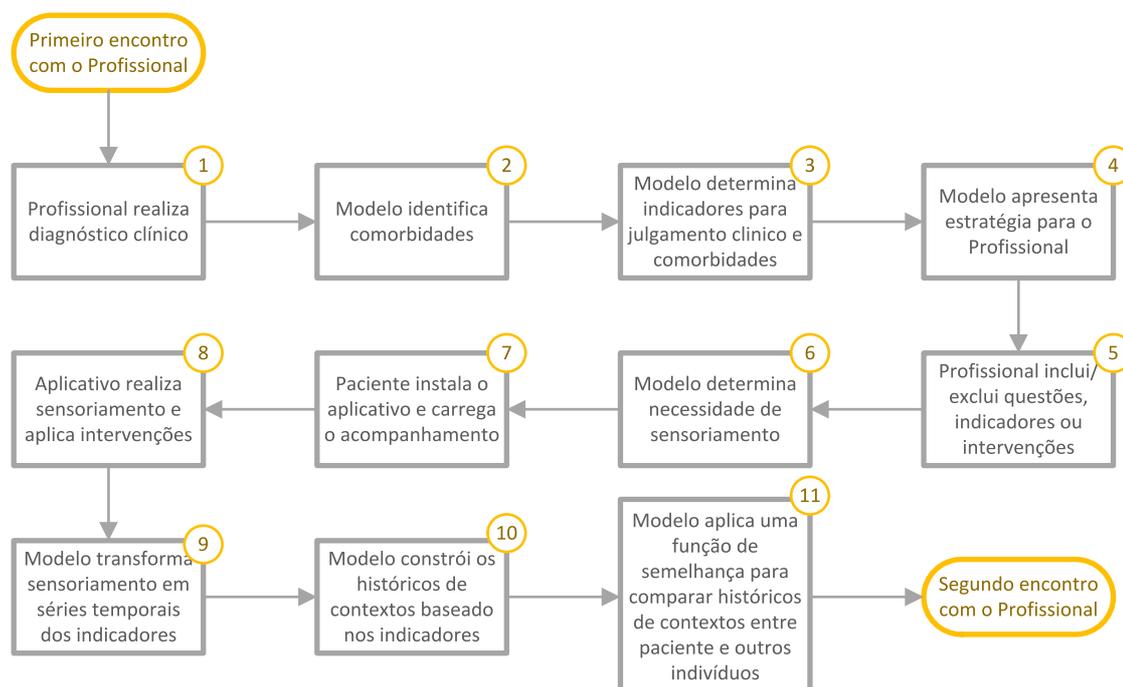
A **quarta etapa** corresponde à construção dos perfis por população, bem como na aplicação de algoritmos de classificação para identificação de padrões nos grupos afetados pelos transtornos, que permite a última etapa realizar a revisão dos perfis epidemiológicos, realizar investigações de etiologia de transtornos e adaptar políticas de saúde pública para ter maior impacto na população mais vulnerável a transtornos neuropsiquiátricos.

Ela se baseia na execução de expressões de busca na ontologia para extrair informações dos perfis epidemiológicos a partir de inferências de classes, derivada dos dados identificados na primeira e segunda etapa do processo de construção de perfis epidemiológicos.

4.4 Fluxo de processos do modelo

Esta seção apresenta o modelo em forma de fluxo de processo, com o objetivo de facilitar a compreensão na aplicação prática do mesmo. A figura 18 apresenta o fluxo entre o primeiro encontro com o profissional até o segundo encontro, composto de onze etapas.

Figura 18: Fluxograma do modelo no primeiro encontro com o profissional



Fonte: Elaborado pelo autor.

1. Profissional realiza diagnóstico clínico: A primeira etapa, vinculada ao conceito de **Diagnóstico**, é a realização do diagnóstico clínico realizado pelo profissional. Esta etapa ocorre geralmente a partir de uma entrevista entre o profissional e o paciente ou familiar. Nesta etapa o profissional determina um diagnóstico preliminar, em forma de quais transtornos ele entende que estejam se manifestando e sua confiança em cada transtorno diagnosticado. O profissional então registra o paciente com seus dados sociodemográficos na plataforma, e pode gravar o diálogo do primeiro encontro para avaliação posterior.

2. Modelo identifica comorbidades: A segunda etapa, vinculada aos conceitos de Diagnóstico e Indicadores, pertence à parte automatizada do modelo em identificar comorbidades, baseado tanto nos perfis epidemiológicos gerados pela plataforma como baseados em um repositório de informações de pesquisas da área de neuropsiquiatria.

3. Modelo determina indicadores para julgamento clínico e comorbidades: A terceira etapa, vinculada ao conceito de **Indicadores**, é o momento em que o modelo identifica os melhores indicadores para a confirmação do diagnóstico pelo profissional. A determinação de indicadores é realizada a partir do julgamento clínico, e utiliza a mesma base de informações utilizada para comorbidades. Esta etapa irá influenciar quais os sensores necessários para confirmar o transtorno diagnosticado. Ainda nesta etapa são identificadas sugestões para intervenções ecológicas para suportar o tratamento do transtorno, bem como questionários para indicadores que não possuem sensoriamento passivo.

4. Modelo apresenta estratégia para o profissional: A quarta etapa, ainda vinculada ao conceito de Indicadores e diretamente relacionada à necessidade de incorporar o profissional no processo de gerenciamento de transtornos, é onde o modelo apresenta ao profissional as comorbidades, indicadores e intervenções identificados nas etapas anteriores.

5. Profissional inclui/exclui indicadores ou intervenções: A quinta etapa, complementar a etapa anterior, permite ao profissional modificar e agendar as intervenções e

indicadores para o paciente em questão, caso entenda que os mesmos não são aplicáveis ou prefira outras formas de confirmação de diagnóstico.

6. Modelo determina necessidade de sensoriamento: A sexta etapa, vinculada ao **Sensoriamento**, é responsável por identificar os sensores passivos necessários para construção dos indicadores, bem como é responsável por determinar e agrupar as formas de sensoriamento ativo necessários para indicadores que não suportem formas passivas de construção.

7. Paciente instala o aplicativo e carrega o acompanhamento: A sétima etapa, é onde a plataforma passa efetivamente a monitorar e gerenciar os transtornos do paciente. Esta etapa consiste na instalação do aplicativo e no uso dos dispositivos relacionados.

8. Aplicativo realiza sensoriamento e aplica intervenções: A oitava etapa, relacionada aos conceitos de **Sensoriamento**, **Tratamento** e **Intervenção**. É onde o sensoriamento ativo e passivo é realizado, bem como a aplicação das intervenções determinadas pelo profissional de saúde. É neste momento em que o aplicativo pode alertar o paciente sobre medicações, entregar conteúdo educacional, questionar o paciente sobre seu humor, ou alertar o mesmo sobre comportamentos prejudiciais ao seu quadro clínico.

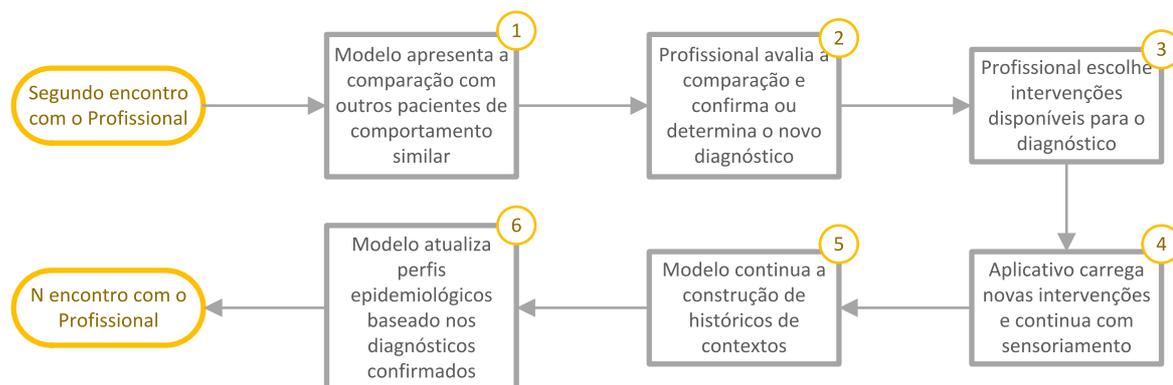
9. Modelo transforma sensoriamento em séries temporais dos indicadores: Nona etapa, relacionado ao conceito de **Contexto**, ocorre em paralelo com a etapa anterior, onde continuamente o modelo transforma dados de sensores em séries temporais e armazena no repositório de sensoriamento. Também durante esta etapa os dados dos sensores são transformados em indicadores.

10. Modelo constrói históricos de contextos baseado nos indicadores: Décima etapa, relacionada aos conceitos de **Contexto**, também ocorre continuamente com as duas etapas anteriores, é o momento em que o modelo transforma indicadores em contextos, e contextos em históricos de contextos.

11. Modelo aplica uma função de semelhança para comparar históricos de contextos entre paciente e outros indivíduos: Última etapa no fluxo do primeiro encontro, relacionado ao conceito de **Históricos de Contextos**, é o momento em que o modelo aplica uma função de semelhança, como a distância euclidiana entre *eigenbehaviors*, para determinar se os indicadores e contextos capturados até o momento são semelhantes ao de outros indivíduos com o mesmo diagnóstico. Ao longo do tratamento é este o momento em que o modelo consegue identificar se o comportamento do paciente está se afastando dos comportamentos identificados no transtorno e se aproximando dos históricos de pacientes saudáveis.

A figura 19 apresenta o fluxo dos encontros subsequentes, onde o ciclo de diagnóstico, tratamento e acompanhamento acontece de forma contínua, até o término do tratamento.

Figura 19: Fluxograma do modelo nos encontros subsequentes



Fonte: Elaborado pelo autor.

1. Modelo apresenta a comparação com outros pacientes de comportamento similar: Primeira etapa do segundo encontro, relacionada ao conceito de **Acompanhamento**, é o momento em que o profissional avalia o andamento do tratamento baseado no relatório de comportamento e aderência às intervenções. Neste momento o profissional pode verificar como a rotina do paciente em tratamento se assemelha ou difere de outros pacientes diagnosticados com o mesmo transtorno.

2. Profissional avalia a comparação e confirma ou determina o novo diagnóstico: Etapa relacionada ao conceito de **Confirmação**, é quando o profissional pode confirmar se o diagnóstico anterior está correto ou se o transtorno que está se manifestando é diferente do julgamento clínico original.

3. Profissional escolhe intervenções disponíveis para o diagnóstico: Etapa da continuidade do tratamento, onde o profissional pode agendar novos tipos de intervenção, alterar a recomendação farmacológica, ou sugerir novos exercícios ao paciente.

4. Aplicativo carrega novas intervenções e continua com sensoriamento: Momento onde o aplicativo carrega as novas instruções para sensoriamento e intervenção, baseado no novo diagnóstico, na mudança de indicadores, ou na mudança nas intervenções.

5. Modelo continua a construção de históricos de contextos: Etapa equivalente a décima etapa do fluxograma anterior, onde o modelo continua a montar históricos de forma contínua. Com a confirmação do diagnóstico e a evolução do quadro clínico, esse histórico se torna base para comparação de evolução do tratamento.

6. Modelo atualiza perfis epidemiológicos baseado nos diagnósticos confirmados: Etapa onde os perfis epidemiológicos são atualizados junto com a utilização do modelo. É importante destacar que é esperado que os perfis epidemiológicos mudem ao longo do tempo e que determinados transtornos sofram surtos causados por problemas econômicos, sociais, desastres naturais, entre outras causas. Portanto o perfil epidemiológico atual, a existência de sazonalidade, e como o mesmo evoluiu ao longo do tempo pode ser utilizado para compreensão de determinados transtornos.

Esta seção apresentou dois fluxogramas, sendo que o primeiro fluxograma apresentado na figura 18 é responsável por exemplificar a aplicação da plataforma entre o primeiro encontro de profissional e paciente até o segundo encontro, enquanto o segundo fluxograma apresentado na figura 19 ilustra os encontros subsequentes.

Estes fluxogramas ilustram a interação profissional e paciente, como o modelo suporta essa interação, e exemplifica a continuidade entre diagnóstico, tratamento e acompanhamento, e como esse fluxo alimenta históricos de contextos e perfis epidemiológicos.

4.5 Eigenbehaviors e Eigenroutines

Conforme apresentado na seção 2.6, a modelagem utilizada para identificação e comparação de históricos de contextos é através de uma abordagem baseada em *Eigenbehaviors*. Esta seção detalha como o mesmo pode ser aplicado para identificar rotinas nos históricos de contextos de indivíduos, formar um grupo de comportamento para um determinado transtorno, e ser utilizado para comparar variações de rotinas.

Eigenbehaviors é um termo cunhado por Nathan Eagle, que nada mais é que a identificação dos componentes principais de uma base de dados de comportamento do indivíduo. No *Eigenroutines* o comportamento aproximado de um dia específico é representado pela soma ponderada dos componentes mais significativos, sendo que variáveis discretas são comparadas com sua diferença da média, enquanto contínuas são padronizadas dentro de uma escala de -1 a 1 dentro de uma janela de tempo determinada.

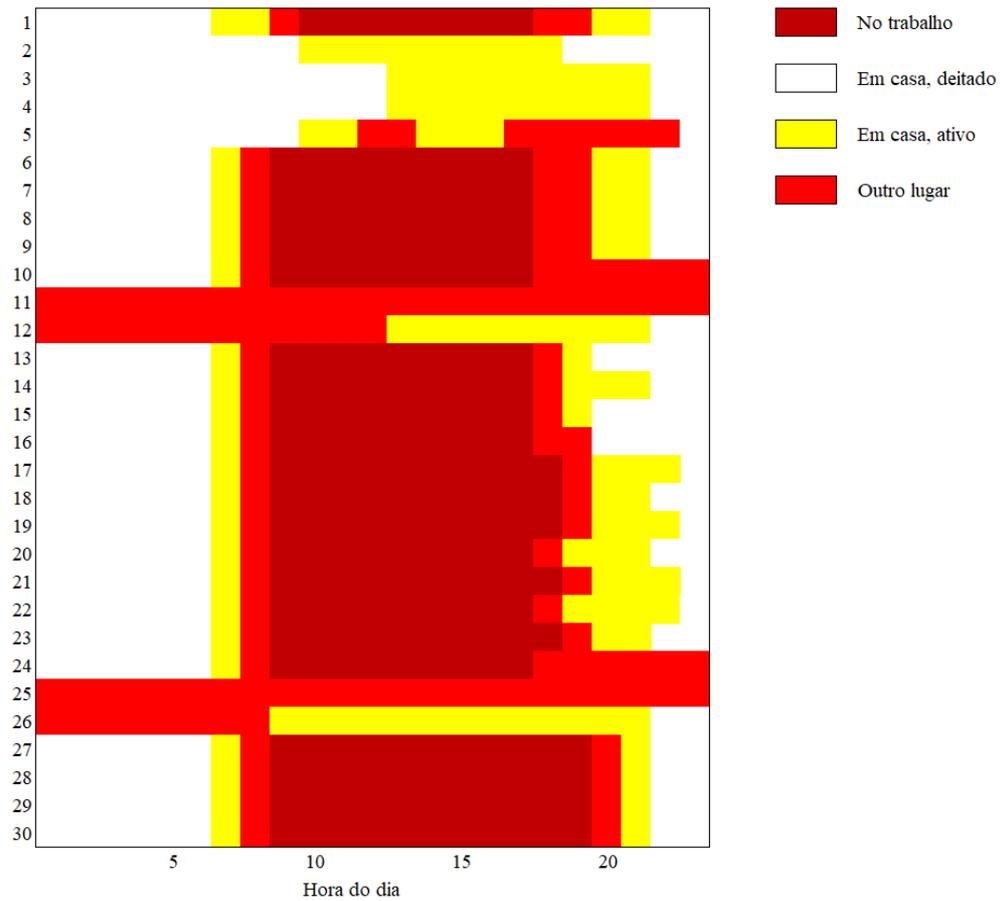
Por motivos de clareza, o exemplo abaixo vai focar em dados de localização temporal aplicados a indicadores de saúde mental, conforme apresentado na seção 4.1.

É importante notar que neste trabalho um conjunto de indicadores são utilizados como uma forma de identificar um comportamento que caracterize um transtorno, portanto a seguir o conjunto de indicadores será referido apenas como comportamento. Também é importante salientar que no modelo *Eigenroutines* um mesmo indivíduo pode ter diversos *Eigenbehaviors* calculados, sendo que a matriz utilizada para o cálculo de rotinas é baseada apenas nos indicadores que se aplicam a um determinado transtorno, ou seja, um indivíduo que tem dois potenciais transtornos identificados deve ter dois grupos de *Eigenbehaviors* calculados.

Considere um indivíduo (i), que por 30 dias (D) teve o contexto capturado pelo modelo, onde o indicador utilizado são as seguintes classificações de comportamento (1) em casa e ativo, (2) em casa e deitado, (3) no trabalho, (4) outro lugar em janelas de tempo de 1 hora (h).

Estes dados podem ser caracterizados por uma matriz bidimensional (B) de tamanho 30 (D) por 24 (h) cujo conteúdo da matriz é o estado e em que o indivíduo i se encontra. A figura 20 ilustra essa matriz. Este estado pode conter variáveis contínuas (e_c) ou discretas (e_d)

Figura 20: Exemplo de matriz de comportamento



Fonte: Elaborado pelo autor, baseado em (EAGLE; PENTLAND, 2009).

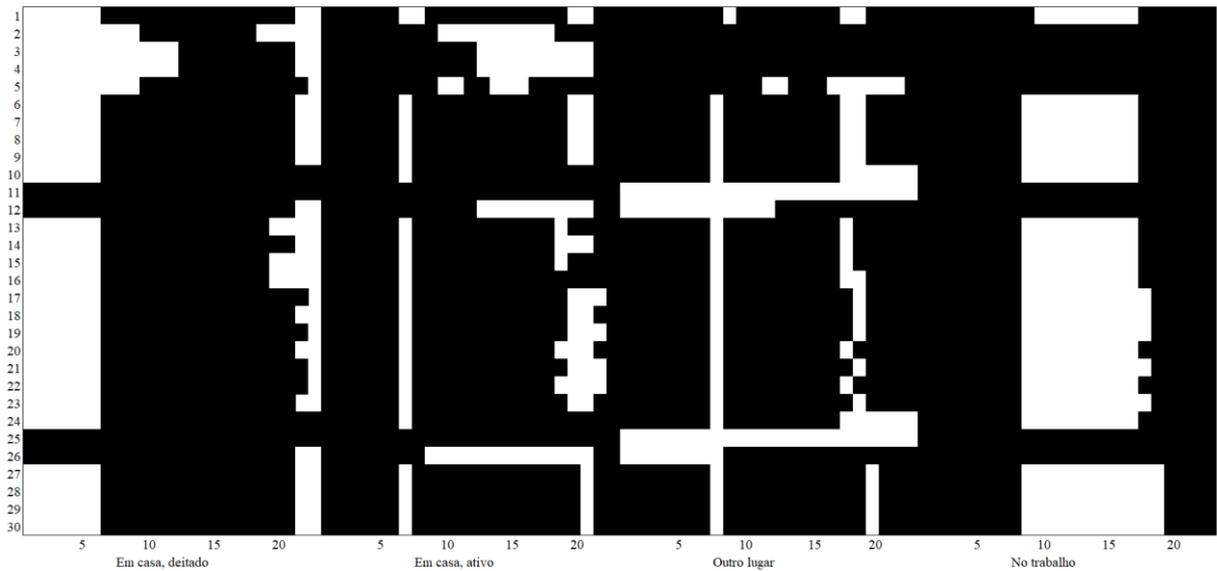
O primeiro passo para identificar a estrutura da rotina de um indivíduo é converter a matriz B em B' com tamanho D por H , sendo $H = (H_c + H_d)$ onde $H_c = tamanho(e_c) \times h$, e $H_d = tamanho(e_d) \times h$. No caso deste exemplo a matriz tem dimensões 30 (D) por 96 (H).

Esta matriz deve conter valores binários representando cada estado no período de um dia. A figura 21 mostra um exemplo desta conversão, onde Γ_d é uma linha na matriz B' e representa o comportamento do indivíduo i ao longo do dia d .

Devido a uma quantidade expressiva de similaridade na estrutura do dia a dia dos indivíduos, essas classificações não estão aleatoriamente distribuídas em todo o espaço $D \times H$. O comportamento do indivíduo pode ser agrupado em um espaço dimensional menor referido como “espaço de comportamento”.

Este espaço é definido como um grupo de vetores de dimensão H que melhor caracterizam a distribuição do comportamento do indivíduo, e são referidos como os *eigenbehaviors* primários, que basicamente é a análise dos componentes principais desta matriz binária normalizada.

Figura 21: Matriz de comportamento em representação binária



Fonte: Elaborado pelo autor, baseado em (EAGLE; PENTLAND, 2009).

Os dados de contexto podem prover uma série de vetores de comportamento, $\Gamma_1, \Gamma_2, \Gamma_3 \dots \Gamma_D$ por um total de D dias, onde cada vetor Γ_d possui dimensão H_d . A partir desse grupo de vetores, é possível normalizar as variáveis discretas calculando o comportamento médio de um indivíduo conforme apresentado na equação 2.

Equação 2: Média de comportamento de variáveis discretas de um indivíduo em D dias

$$\Psi_d = \frac{1}{D} \sum_{n=1}^D \Gamma_n$$

Fonte: Elaborado pelo autor, baseado em (EAGLE; PENTLAND, 2009).

Uma vez computado o comportamento médio para variáveis discretas, deve se computar o desvio de comportamento em relação à média, conforme apresentado na equação 3.

Equação 3: Desvio de comportamento de variáveis discretas em relação à média

$$\Phi_d = \Gamma_d - \Psi$$

Fonte: Elaborado pelo autor, baseado em (EAGLE; PENTLAND, 2009).

Para evitar o sobre peso de variáveis contínuas na decomposição espectral da matriz de comportamento se realiza uma normalização destas variáveis para a mesma escala da média de comportamento do indivíduo (ou seja, entre -1 e 1). Essa normalização é apresentada na equação 4.

Equação 4: Normalização das variáveis contínuas do vetor de comportamento

$$\Phi_c = \frac{(\Gamma - \min(\Gamma)) \times (1 - (-1))}{(\max(\Gamma) - \min(\Gamma)) + (-1)}$$

Fonte: Elaborado pelo autor.

Sendo o resultado final a concatenação de ambas as matrizes conforme a equação 5.

Equação 5: Matriz resultante com variáveis discretas e contínuas

$$\Phi = \Phi_d | \Phi_c$$

Fonte: Elaborado pelo autor.

A partir desta matriz resultante é possível montar uma matriz de covariância (C) com dimensão H e realizar uma Eigen-decomposição (ou decomposição espectral) da matriz C encontrando autovetores e autovalores, que quando combinados linearmente resultam nos *eigenbehaviors* u , conforme apresentado na equação 6. Pode se obter o mesmo resultado realizando uma análise de componentes principais da matriz Φ e obtendo os autovetores ordenados pelos seus autovalores.

Equação 6: Matriz de covariância C da matriz Φ

$$C = \frac{1}{H} \sum_{n=1}^H \Phi_n \Phi_n^T$$

Fonte: Nathan Eagle (EAGLE; PENTLAND, 2009).

Esta técnica pode ser aplicada tanto ao comportamento de um indivíduo ao longo do tempo, quanto ao comportamento médio de múltiplos indivíduos. A vantagem de calcular *eigenbehaviors* para um grupo é a possibilidade de calcular a distância do comportamento médio de um indivíduo da média do grupo.

Se o comportamento de um indivíduo em diagnóstico preliminar de depressão está próximo do comportamento médio de indivíduos com diagnóstico confirmado depressão, então é provável que o mesmo esteja efetivamente com depressão.

4.5.1 Comparação de rotinas

No Eigenroutines a classificação de um indivíduo como parte de um grupo com ou sem transtorno é realizada em duas etapas: (1) é realizada uma classificação adaptativa das rotinas em relação aos demais indivíduos, (2) é realizado um cálculo de distância do indivíduo em relação ao grupo para a evolução da rotina, comparando a distância em dois pontos distintos do tempo.

Para a primeira etapa, os *eigenbehaviors* computados na janela de tempo onde indivíduos classificados com um determinado transtorno por um profissional são utilizados para treinar classificadores supervisionados.

Considere um o indivíduo (i) acompanhado por 90 dias (D), onde o mesmo tenha sido avaliado por um profissional de saúde nos dias 15, 30, 45, 60, 75 e 90. Se o profissional diagnosticar o indivíduo como apresentando sintomas de depressão profunda no dia 15, e como assintomático no dia 75, podemos então utilizar o histórico de contexto entre o dia 0 e o dia 60 como referência para um indivíduo com depressão, e do dia 61 ao dia 90 como referência para indivíduo saudável.

Esta segregação de contexto serve tanto para classificação, como utilização de cálculo de média de comportamento utilizado na equação 7.

Uma vez determinado a base de histórico de contexto a ser utilizada, *eigenbehaviors* são extraídos para cada indivíduo conforme a equação 6, e classificadores supervisionados devem ser treinados baseados nestes contextos e avaliados utilizando validação cruzada, onde os classificadores mais precisos devem ser utilizados para classificar o comportamento de um indivíduo em relação a base de dados de histórico de contextos.

Para a segunda etapa é realizado um cálculo de distância entre indivíduos com objetivo de avaliar a proximidade de um indivíduo em relação a base de histórico de contextos de outros indivíduos.

Considere que para o mesmo indivíduo (i) acompanhado por 90 dias (D) é necessário avaliar a evolução entre os dias 15 ($t15$) e 75 ($t75$). Para isso deve ser realizado o cálculo de distância de comportamento do indivíduo i em relação ao comportamento médio grupo de indivíduos com depressão e ao grupo de indivíduos assintomáticos, e verificar se a distância no tempo $t15$ para o grupo de depressivos é maior que no tempo $t15$ para o grupo de assintomático, assim como o mesmo valor deve ser inverso no tempo $t75$.

Para calcular a distância entre indivíduos é necessário projetar o comportamento do indivíduo no espaço de comportamento do grupo, conforme apresentado na equação 7.

Equação 7: Projeção do comportamento de um indivíduo no comportamento do grupo

$$\omega_k^i = u_k^j(\Gamma_i - \Psi_j)$$

Fonte: Nathan Eagle (EAGLE; PENTLAND, 2009).

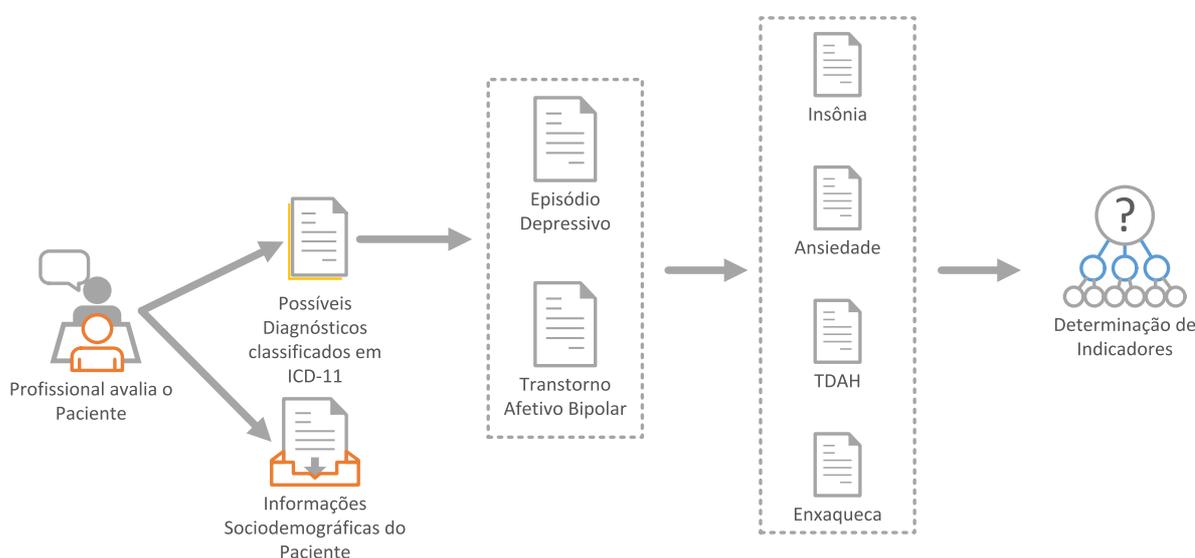
Onde Γ_i é o comportamento médio de um indivíduo i , Ψ_j é o comportamento médio de um grupo j , u_k^j é o *eigenbehavior* k do grupo j . O grupo de pesos ω_k^i para $k = 1, \dots, H$ forma um vetor de pesos $\Omega_i^T = [\omega_1^i, \omega_2^i, \omega_3^i, \dots, \omega_H^i]$ que pode ser utilizando tanto para comparar a similaridade do comportamento de dois indivíduos, quanto à similaridade de um indivíduo com relação ao comportamento médio.

4.6 Cenário de exemplo

Esta seção apresenta os conceitos e fluxogramas das seções anteriores utilizando um cenário de exemplo, onde o objetivo é trazer mais clareza sobre os conceitos em um cenário prático. A figura 22 ilustra um exemplo com as primeiras etapas do diagnóstico.

Neste exemplo o julgamento clínico do profissional registra as informações sociodemográficas do paciente e diagnostica dois possíveis transtornos: (1) Episódio depressivo e (2) Transtorno afetivo bipolar. Destes dois transtornos, quatro comorbidades são identificadas a partir dos transtornos: (1) insônia, (2) ansiedade, (3) transtorno de déficit de atenção e hiperatividade e (4) enxaqueca. Este primeiro exemplo termina na etapa de determinação de indicadores.

Figura 22: Exemplo de diagnóstico até determinação de indicadores

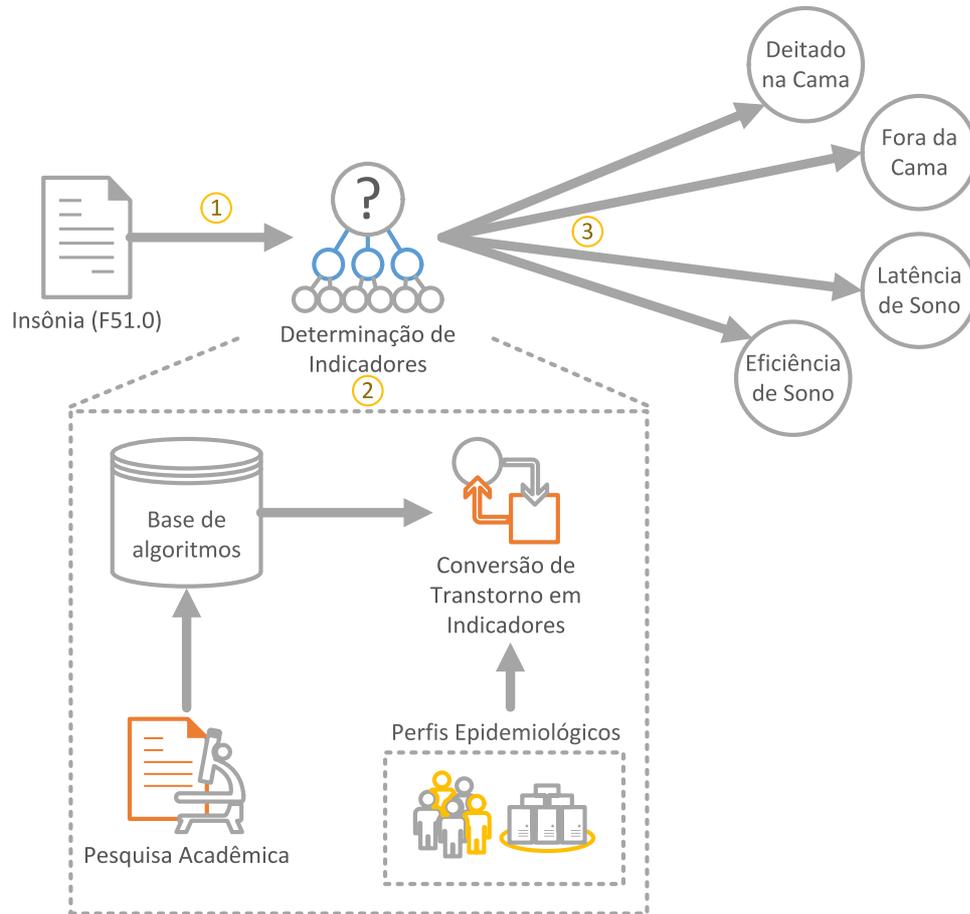


Fonte: Elaborado pelo autor.

A figura 23 apresenta três etapas relacionadas à determinação de indicadores. Neste exemplo o diagnóstico de comorbidade de Insônia não orgânica com classificação F51.0 no ICD-10 é utilizada. A segunda etapa é responsável por comparar na base de algoritmos e perfis epidemiológicos quais os melhores indicadores para realização de diagnóstico.

A terceira etapa é o resultado da determinação de indicadores, onde quatro foram determinados pelo modelo: (1) tempo que o paciente permanece deitado na cama, (2) tempo que o paciente permanece fora da cama, (3) latência de sono, ou seja, quanto tempo o paciente leva para dormir, (4) eficiência de sono, ou seja, quanto tempo o paciente passa deitado em comparação com o tempo que passa dormindo.

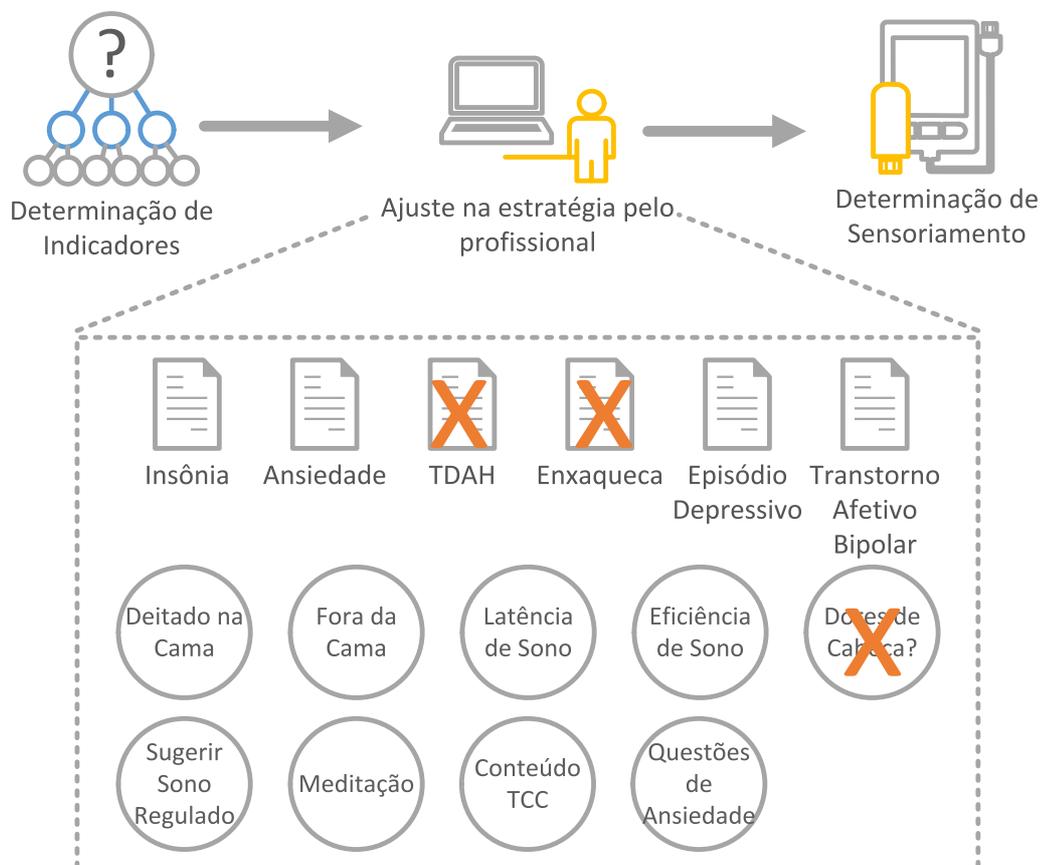
Figura 23: Exemplo de conversão de diagnóstico em indicadores



Fonte: Elaborado pelo autor.

A figura 24 ilustra a interação entre o profissional e os indicadores determinados. Neste exemplo o profissional entende que TDAH e enxaqueca não são aplicáveis, e por consequência um dos sensoriamentos ativos é descartado. Após este exemplo o modelo começa a determinação de sensoriamento baseado nos indicadores.

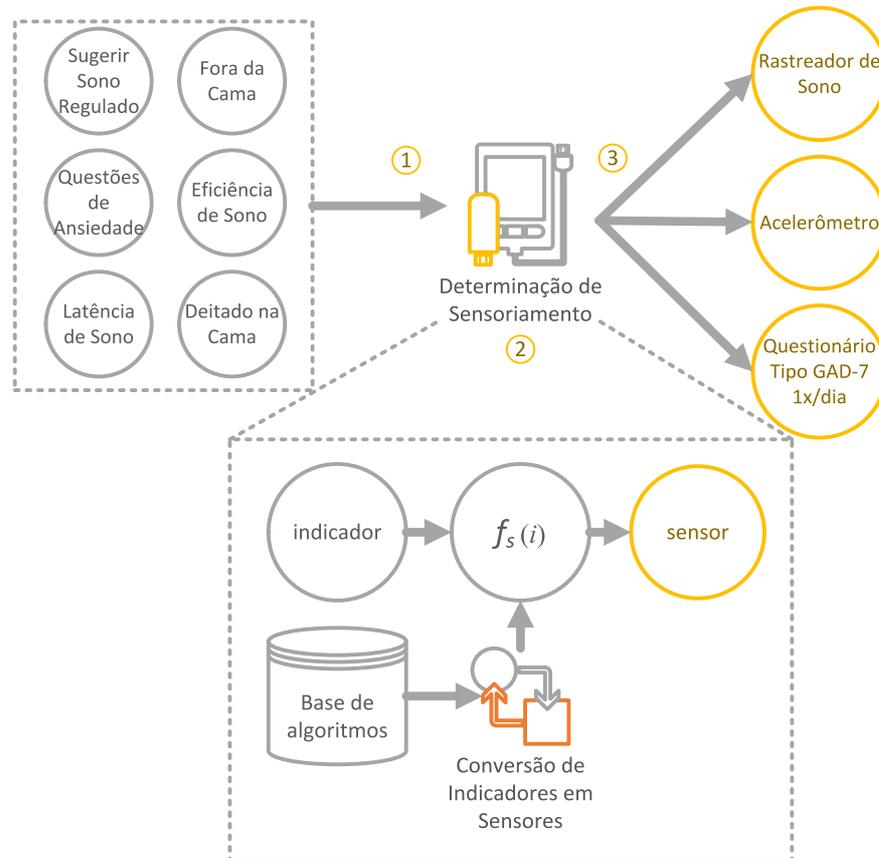
Figura 24: Exemplo de indicadores, seleção de estratégia até definição de sensoriamento



Fonte: Elaborado pelo autor.

A figura 25 apresenta as etapas relacionadas à determinação de sensoriamento. Neste exemplo seis indicadores são utilizados como parâmetros pela determinação. Para cada indicador, uma função de conversão é determinada pela base de algoritmos, onde o resultado da função é a lista de sensores ativos e passivos utilizados pelo indicador. O resultado da determinação de sensoriamento nesta figura de exemplo é a utilização de um rastreador de sono (p. ex. FitBit ou aplicativo *SleepCycle*), de informações de acelerômetro, e da realização diária de um questionário com equivalência ao *Generalized Anxiety Disorder 7-item (GAD-7)*.

Figura 25: Exemplo de conversão de indicadores em sensores

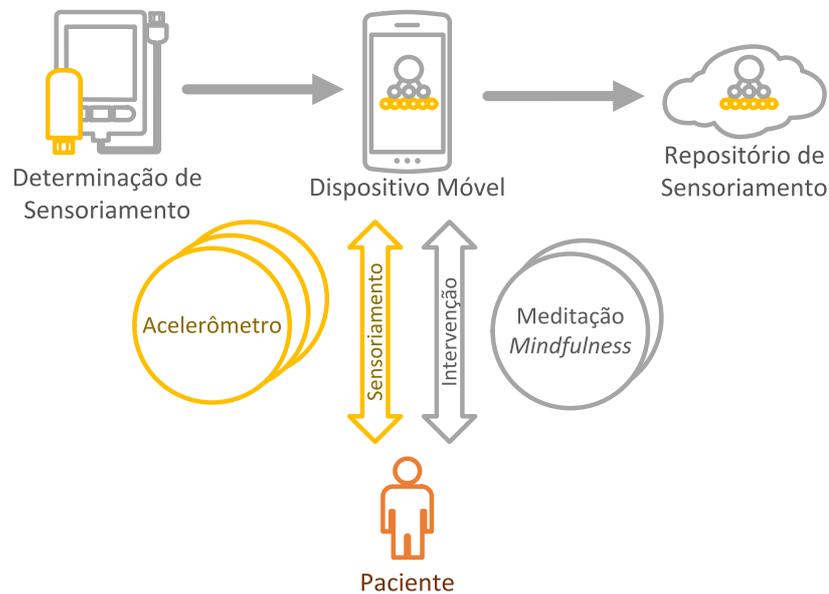


Fonte: Elaborado pelo autor.

A figura 26 ilustra a continuação da determinação de sensoriamento. Nesta figura o dispositivo móvel carrega as informações de sensoriamento e intervenção, e aplica as mesmas no paciente de acordo com o agendamento.

Neste exemplo é destacado o monitoramento do acelerômetro conforme a necessidade determinada pelos indicadores dos transtornos em avaliação, bem como a aplicação de intervenção baseada em meditação *Mindfulness*. Esta ilustração termina com a sincronização das informações de sensoriamento e aderência a intervenções para o repositório de sensoriamento, conforme já ilustrado pela figura 15.

Figura 26: Interação entre sensoriamento, dispositivo móvel, paciente e repositório de sensoriamento

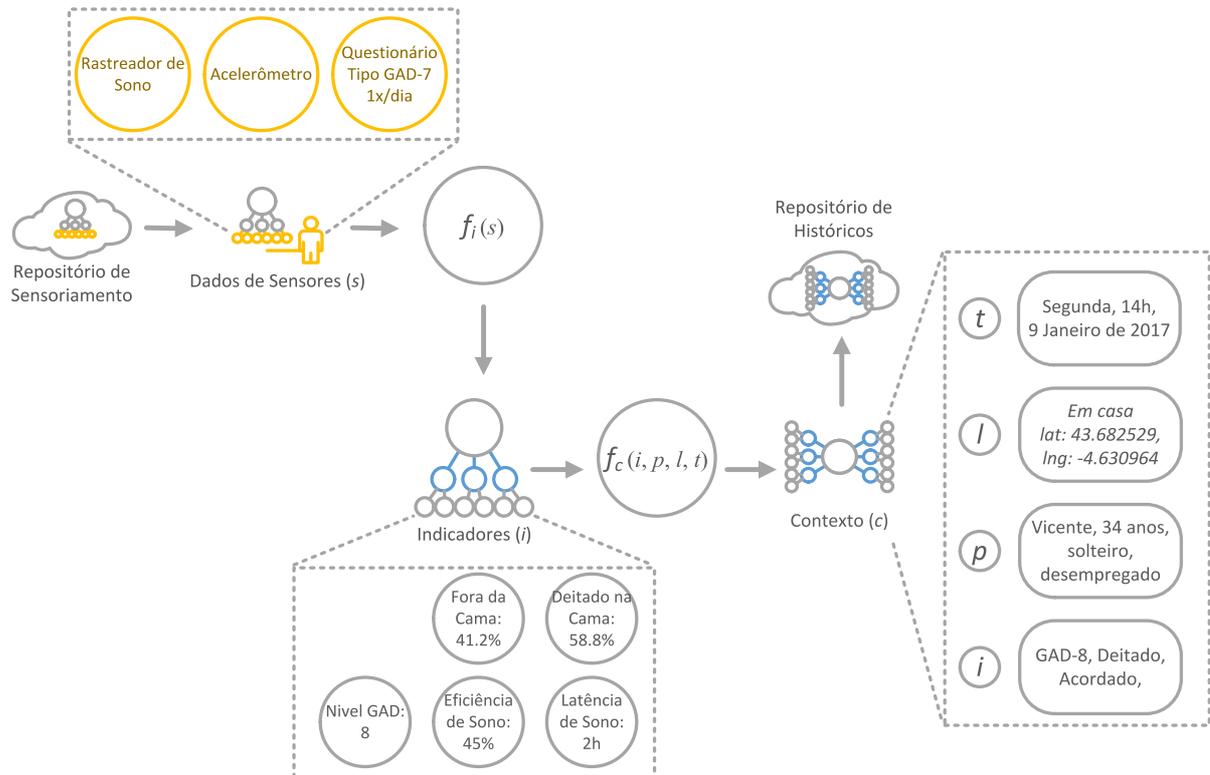


Fonte: Elaborado pelo autor.

A figura 27 ilustra a etapa de utilização das informações resultantes do sensoriamento até a construção dos históricos de contexto. Nesta figura as informações recuperadas pelos sensores são transformadas em indicadores a partir de uma função adaptativa, conforme explicado na seção 4.1 e ilustrado na figura 14. Esta função adaptativa resulta em indicadores quantificados em uma escala de tempo, no exemplo é apresentado que o paciente ficou apenas 41.2% do seu tempo fora da cama, que a latência de sono foi de pelo menos 2 horas, que teve 45% de eficiência de sono, e que o resultado do questionário foi 8 pontos na escala GAD-7, o que representa um estado de ansiedade média.

Estes indicadores são então utilizados para construção do contexto, onde também se utiliza a dimensão de tempo t (9 de janeiro de 2017 no exemplo), lugar l (marcador “em casa” e posição precisa via latitude e longitude), perfil do paciente p e indicadores i .

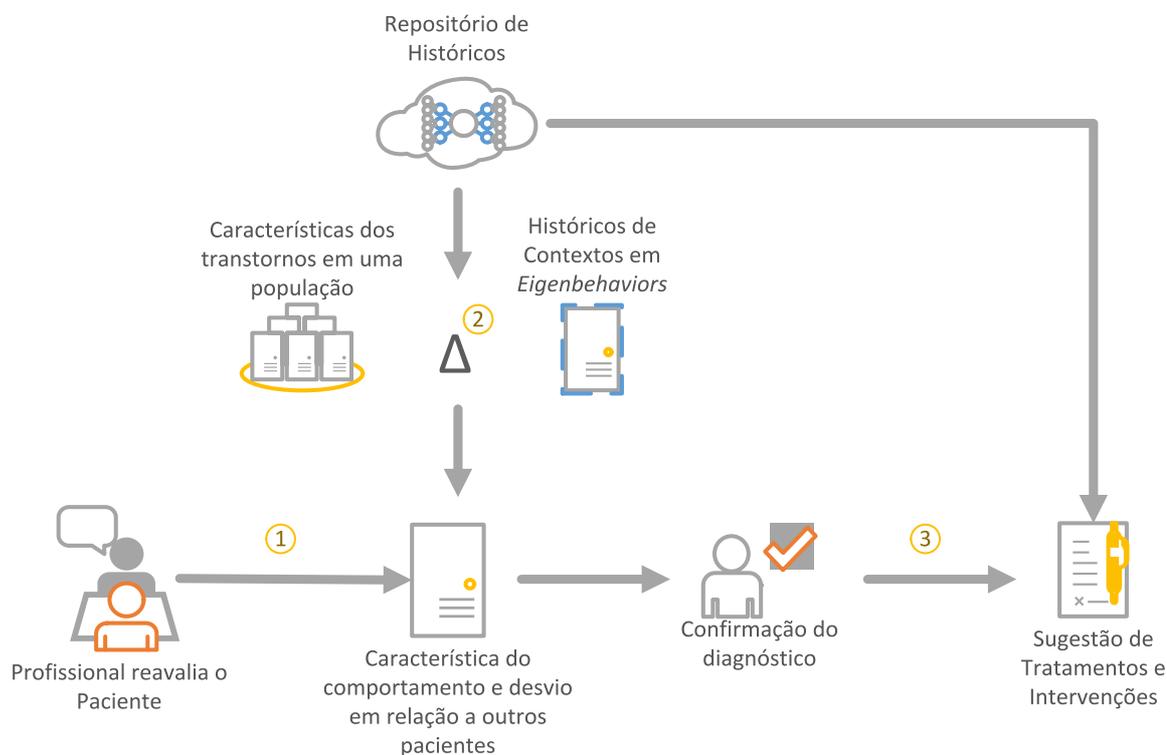
Figura 27: Exemplo de conversão de sensoriamento em indicadores e de indicadores em contexto



Fonte: Elaborado pelo autor.

A figura 28 apresenta o uso do histórico de contextos em três etapas. A primeira etapa começa com o profissional reavaliando o paciente. Como suporte a essa reavaliação, o modelo realiza uma comparação Δ , que é a semelhança entre o comportamento do paciente quando comparado ao comportamento de outros pacientes já com diagnóstico confirmado. Essa comparação é agregada em um relatório para o profissional de saúde, cujo conteúdo contém: (1) a aderência do paciente ao tratamento e intervenções escolhidas, (2) os resultados dos indicadores escolhidos, (3) a similaridade da rotina do paciente em comparação ao histórico de outros pacientes, bem como quais transtornos e severidades foram identificadas nos outros pacientes.

A segunda etapa termina assim que o profissional confirma o diagnóstico preliminar, e continua na terceira etapa, onde o modelo sugere intervenções baseado nos históricos de contextos dos outros pacientes que já apresentaram melhoras de quadro clínico.

Figura 28: Exemplo no uso do histórico de contextos para suportar o tratamento

Fonte: Elaborado pelo autor.

4.7 Arquitetura

Nesta seção é apresentada a arquitetura proposta para suportar o modelo. Dentre os principais desafios e requisitos arquiteturas a serem considerados pelo software estão: (1) sistemas distribuídos com conectividade intermitente, (2) extensibilidade para diferentes transtornos, (3) armazenagem de dados de sensoriamento, (4) suporte a dispositivos heterogêneos, (5) funções adaptativas para indicadores e construção de contextos.

O primeiro desafio, que se refere a sistemas distribuídos com conectividade intermitente é devido a inerente necessidade de se realizar um acompanhamento contínuo.

Esse acompanhamento pode ser realizado a partir de apenas um *smartphone* ou de um *smartphone* acompanhado de tecnologias vestíveis.

Nestas situações é possível que a conectividade para sincronização do estado atual do usuário com os repositórios pode estar limitada em determinados momentos. Portanto para lidar com tais situações, a arquitetura deve ser capaz de armazenar o sensoriamento no próprio dispositivo e sincronizar com o repositório uma vez que a conectividade é reestabelecida.

O segundo ponto a ser considerado na arquitetura é capacidade de extensibilidade para diferentes transtornos se deve a uma série de avanços e pesquisas sendo realizadas na área de neuropsiquiatria, especialmente na aplicação de dispositivos móveis para identificação ou tratamento de transtornos mentais. Portanto se faz necessária o uso de técnicas que permitam a extensão da plataforma para novas técnicas e formas de intervenção sem fragmentar a experiência do profissional de saúde mental. A arquitetura para implementação deste modelo

deve considerar esses aspectos e prover meios de extensão com o devido acesso a informações e as capacidades dos *smartphones* e *wearables*.

Como terceiro desafio, é importante considerar os impactos arquiteturais necessários para a armazenagem de dados de sensoriamento uma vez que o volume de informações captadas por um sensor acompanhando um indivíduo pode causar problemas de desempenho. A avaliação da arquitetura e do modelo precisa levar em consideração a complexidade das inferências para construção dos perfis epidemiológicos de forma a poder lidar com o volume expressivo de dados.

O quarto desafio se deve a possibilidade de que diferentes pacientes terão diferentes dispositivos móveis e vestíveis, e portanto se faz necessário o suporte a dispositivos heterogêneos. O mercado de *smartphones* está dividido primariamente em três grandes plataformas, cada qual com suas capacidades tecnológicas e suas linguagens de programação. A arquitetura para implementação do modelo deve fornecer uma camada de abstração entre a necessidade de sensoriamento e intervenção e a tecnologia necessária para a interação com o usuário ou extração de informação do dispositivo.

Funções adaptativas, relacionado ao segundo desafio, é a condição da arquitetura ser capaz de alterar as funções de escolha de indicadores, escolha de sensores e comparação de históricos, para assim permitir uma melhor precisão na escolha de indicadores. O algoritmo adaptativo seria responsável por comparar a acurácia entre os indicadores e os diagnósticos por julgamento clínico, e então adaptar o uso de indicadores ao longo do tempo.

A figura 29 apresenta a arquitetura proposta em alto nível, e os principais módulos para esta implementação, subdivididos em (1) *CareModules*, (2) *CareRepositories*, (3) *CareContext*, (4) *AgentJS* e (5) *CareDiagnosis*.

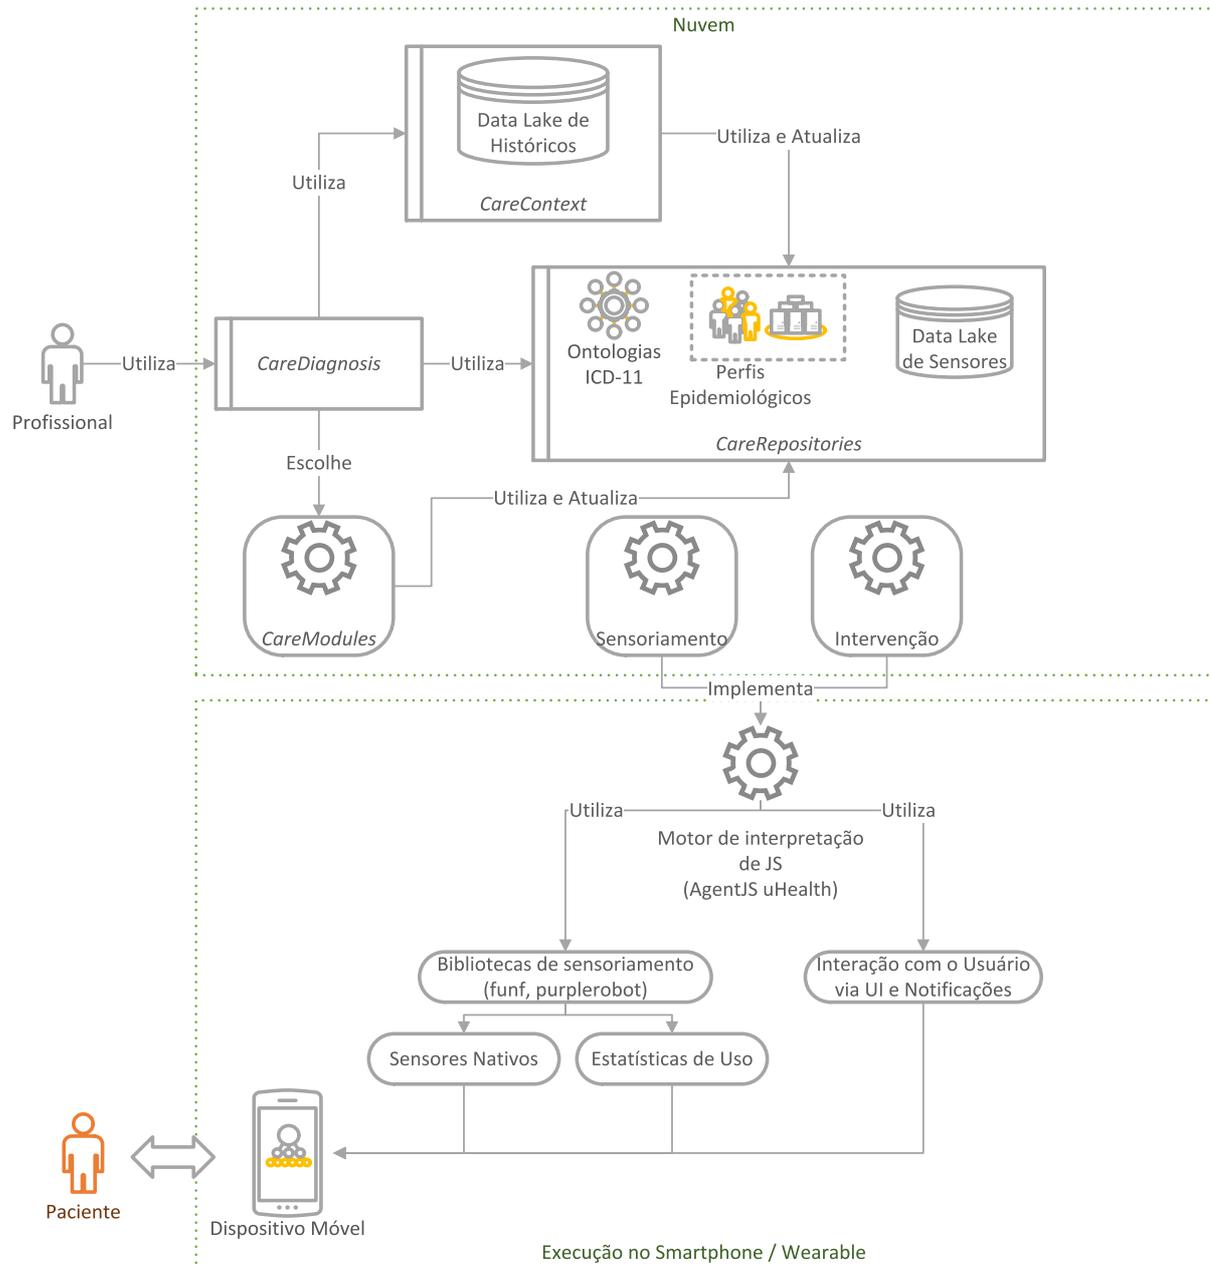
CareModules são os blocos básicos de interação da plataforma. Estes blocos provêm a capacidade de realizar sensoriamento, intervenção ou relatórios de acompanhamento. Ao se adicionar um *CareModule* na plataforma, de fato o que acontece é aumentar a capacidade da mesma em lidar com transtornos, seja por novas formas de intervenção, ou novas formas de detecção de um transtorno.

Um *CareModule* pode ser, por exemplo, um diário que captura a escrita ou fala de um paciente, interpreta o texto, e apresenta uma avaliação semântica para o profissional julgar se o quadro clínico do paciente está evoluindo. Outro exemplo de *CareModule* pode ser um conteúdo de terapia cognitivo comportamental, agendado pelo profissional ou automaticamente ativado de acordo com indicadores. Por fim, um *CareModule* pode ser simplesmente um conjunto de indicadores e formas de sensoriamento utilizados pelo *CareContext* com o objetivo de identificar similaridades entre transtornos.

Todo *CareModule* é um micro serviço registrado na plataforma que interage com a mesma a fim de prover uma determinada funcionalidade. Todo *CareModule* que precisar ter acesso ao paciente e ao dispositivo móvel deve implementar uma interface do *AgentJS* para que o mesmo possa utilizar as ferramentas disponibilizadas pela plataforma. Na figura 29 dois *CareModules* genéricos (Sensoriamento e Intervenção) aparecem ilustrando a sua relação com o motor de execução móvel de javascript *AgentJS*.

CareRepositories são repositórios de informações compartilhadas, entre os módulos da plataforma ou outras plataformas. Estes repositórios deixam explícita a separação entre dados de sensores e dados de contexto. O objetivo do *CareRepositories* é organizar e armazenar essas informações compartilhadas. Ontologias e adaptadores de ontologias fazem parte dos *CareRepositories*.

Figura 29: Arquitetura em alto nível proposta para o modelo



Fonte: Elaborado pelo autor.

CareContext é uma extensão dos *CareModules*, provido pela própria plataforma. O *CareContext* é responsável pela implementação dos algoritmos adaptativos de construção e comparação de contextos e históricos de contextos, e sua função primária é montar históricos de contextos baseados nas informações disponíveis no *CareRepositories*.

CareDiagnosis é a ferramenta de interação com o profissional de saúde mental, e é responsável pelas funções de diagnóstico e acompanhamento do paciente. *CareDiagnosis* interage com *CareModules* e *CareContext* para apresentar relatórios e alertas ao profissional quanto ao andamento do tratamento, e quanto a possibilidade de novos diagnósticos.

AgentJS é uma *application programming interface* (API) e um motor de execução de javascript em dispositivos móveis, capaz de ler códigos em repositórios remotos e executar o mesmo em um dispositivo móvel (BÜTTENBENDER, 2013). Esta plataforma utiliza uma versão estendida do *AgentJS* com instruções específicas de computação ubíqua para saúde mental.

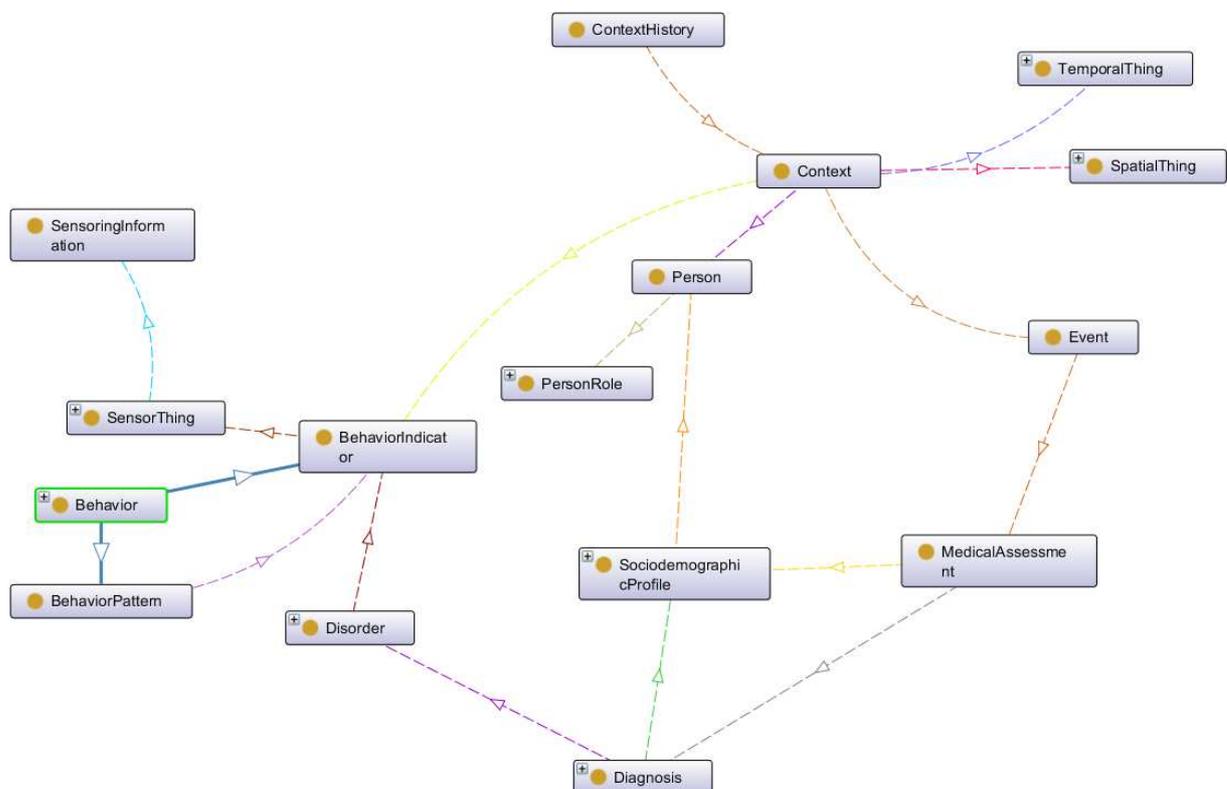
4.8 Ontologia Eigenroutines

Para a representação geral das entidades do modelo e suas relações foi construída uma ontologia composta por classes de uma ontologia de histórico de contextos conforme proposta no *AgentJS* (BÜTTENBENDER, 2013), de classes de uma ontologia pra cuidados ubíquos para saúde mental proposta no *Hígia* (PETRY *et al.*, 2016) e no *iAware* (DIAS, 2018) e de informações para construção de perfis epidemiológicos baseado em uma ontologia existente (FERNANDES, 2012) e em observações da estrutura de perfis epidemiológicos em trabalhos da literatura epidemiológica (BAASCH; TREVISAN; CRUZ, 2017; DALARMELENA; ALMANÇA; OLIVEIRA-CORTEZ, 2017; MOLINA *et al.*, 2012).

A ontologia detalhada nesta seção foi modelada e implementada como forma a facilitar a visualização das entidades e suas relações no modelo, auxiliar a codificação do modelo e para realizar inferências de classes e atributos para a identificação de perfis epidemiológicos, conforme apresentado na seção 5.3.

Esta seção detalha os vários aspectos desta ontologia e suas classes e relações.

Figura 30: Visão geral das classes básicas da ontologia de comportamento

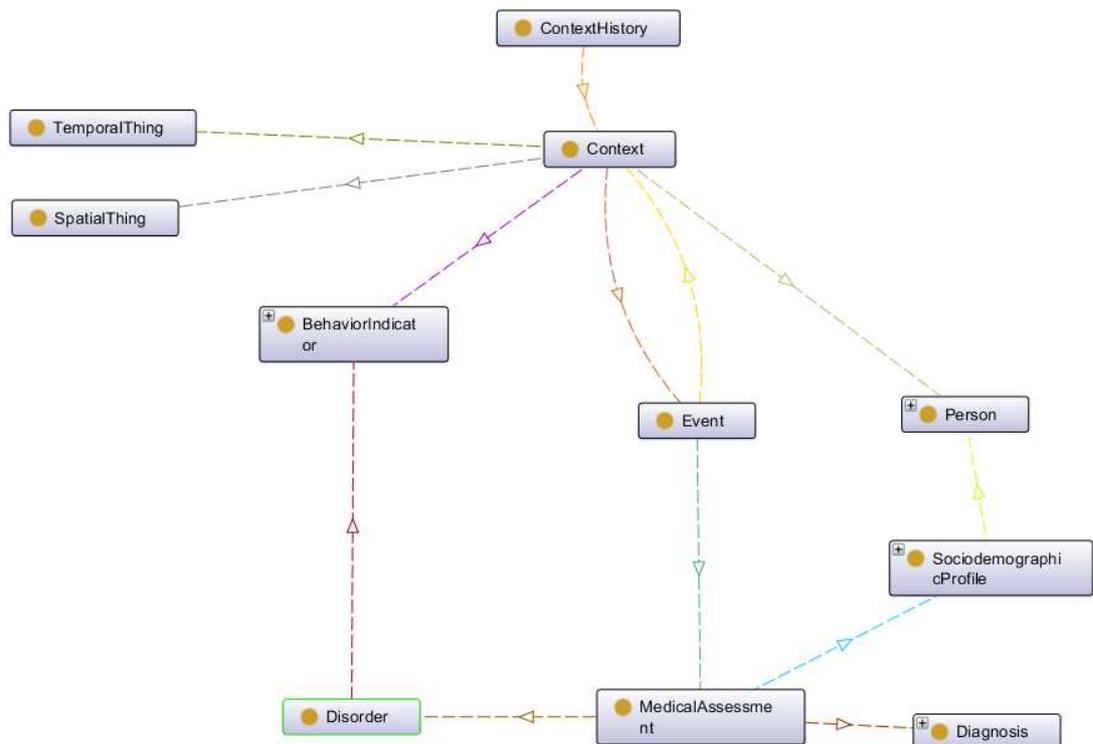


Fonte: Elaborado pelo autor.

A figura 30 apresenta a ontologia com as classes básicas do modelo, estendendo a entidade básica *Thing* da OWL com as seguintes definições:

- **Comportamento (*Behavior*):** Determina a classe base para identificação do comportamento humano, e é composto por indicadores de comportamento e padrões de comportamento.
- **Indicador de Comportamento (*BehaviorIndicator*):** Subclasse de comportamento ilustrado na figura 31, são abstrações geradas por informações de sensoriamento vinculados ao Contexto, de forma a permitir a identificação de padrões relacionados a determinados Transtornos.
- **Padrão de Comportamento (*BehaviorPattern*):** Classe que representa rotinas nos indicadores de comportamento identificadas ao longo do tempo, vinculadas a um histórico de contexto de comportamento.
- **Transtorno (*Disorder*):** Determina o transtorno que está sendo acompanhado, e está vinculado a uma classificação de transtorno no ICD ou DSM. Um transtorno está relacionado a um ou mais indicadores de comportamento e possui subclasses detalhando transtornos específicos, como por exemplo o transtorno de depressão maior representado pela classe *MajorDepression*.
- **Diagnóstico (*Diagnosis*):** Classe que determina o diagnóstico realizado por um profissional de saúde mental, vinculado a um transtorno e classificada em estados e grau de confiança.

Figura 31: Visão detalhada das classes de contexto

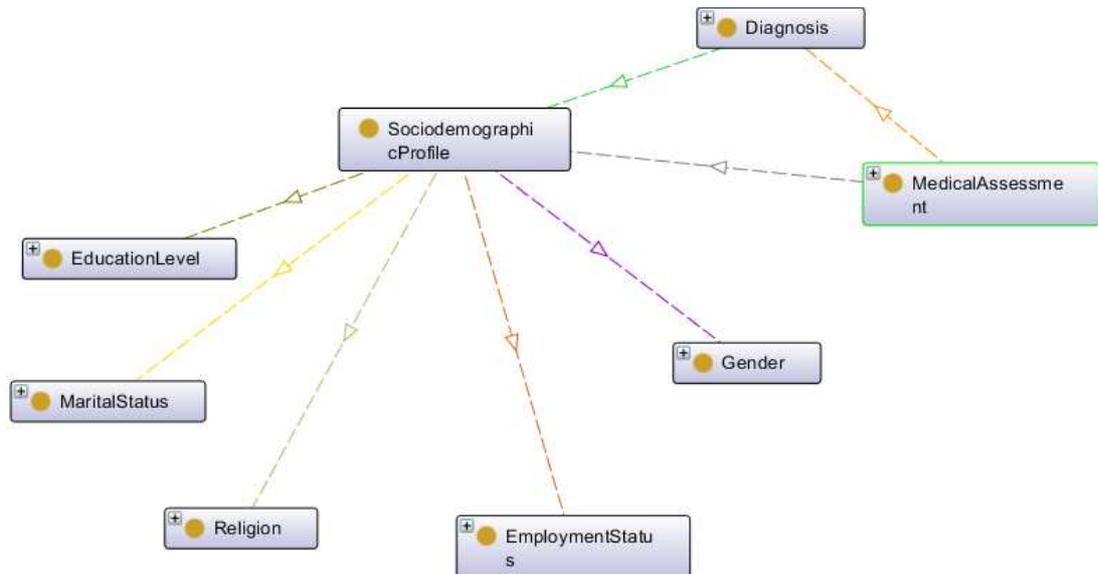


Fonte: Elaborado pelo autor.

- **Evento (*Event*):** Classe que determina um evento em um contexto.

- **Avaliação Médica (*MedicalAssessment*):** Subclasse de evento, que representa uma avaliação médica, detalhada em forma de diagnóstico, transtorno identificado e perfil sociodemográfico.
- **Perfil Sociodemográfico (*SociodemographicProfile*):** Classe que contempla informações sociodemográficas para construção de perfis epidemiológicos, onde instâncias obtém uma definição multi-classe baseada em seus atributos. Instâncias desta classe devem conter todas informações capturadas durante o processo inicial de diagnóstico. Uma vez armazenada a instância do perfil sociodemográfico passa por um processo de inferência na ontologia para extrair definições multi-classe que suportam a construção dos perfis epidemiológicos. Nesta ontologia está prevista classes relativas a faixa etária (classe *AgeGroup*), escolaridade (classe *EducationLevel*), situação empregatícia (classe *EmploymentStatus*), sexo (classe *Gender*), estado civil (classe *MaritalStatus*) e religião (classe *Religion*), ilustrado na figura 32.
- **Pessoa (*Person*):** Classe que representa uma pessoa no sistema, que pode ter um ou mais papéis atribuídos, conforme ilustrado na figura 33.
- **Papel da Pessoa (*PersonRole*):** Classe que representa a função da pessoa no sistema, e está subdividida nas classes de Paciente (*Patient*), Profissional (*Professional*) e Suporte (*Support*).

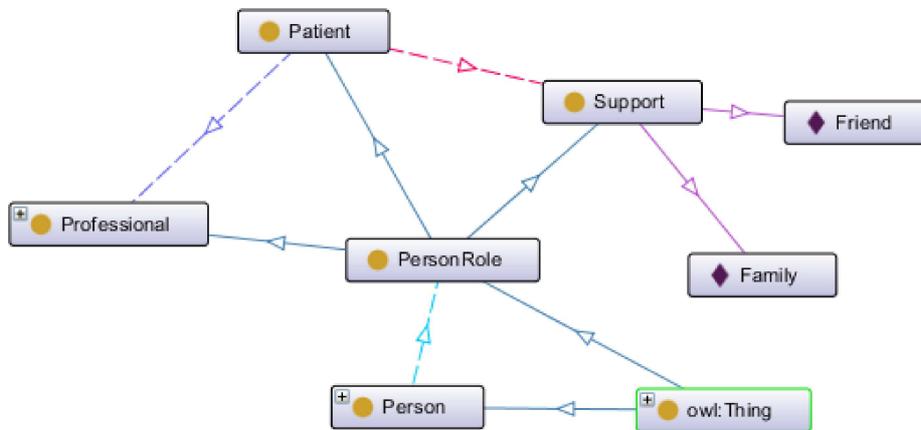
Figura 32: Classes relacionadas ao perfil sociodemográfico



Fonte: Elaborado pelo autor.

- **Coisa de Sensoriamento (*SensorThing*):** Classe que representa sensores ativos e passivos disponibilizados nos *smartphones* ou *wearables*, é responsável por gerar novas instâncias de informação de sensoriamento.
- **Informação de Sensoriamento (*SensingInformation*):** Um pacote de informações relacionadas a um determinado sensor, vinculado a um ponto ou janela de tempo.

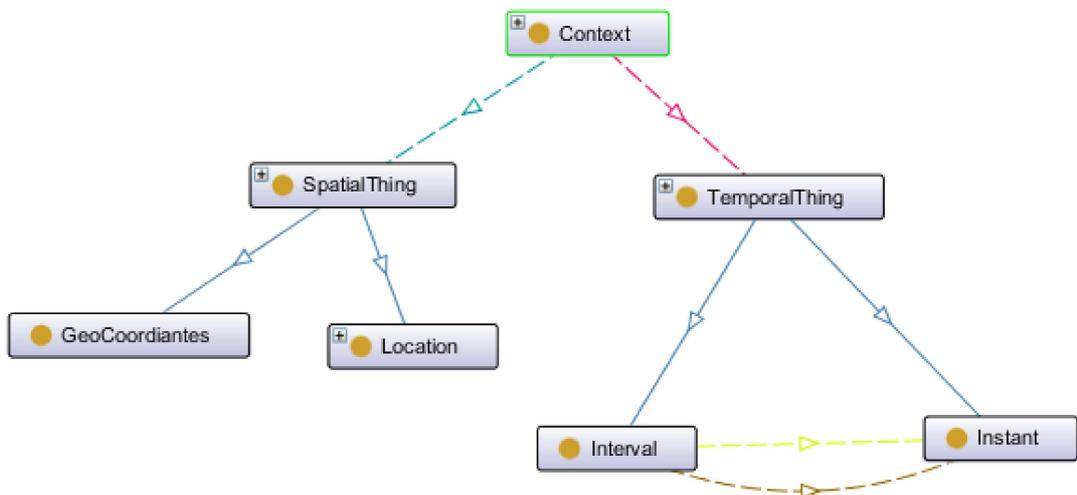
Figura 33: Visão detalhada da ontologia em relação a classe Pessoa.



Fonte: Elaborado pelo autor.

- **Coisa Espacial (*SpatialThing*):** Classe que representa um lugar físico, podendo ser descrito tanto por coordenadas geográficas quanto por uma legenda (p. ex., “Em casa” ou “No trabalho”).
- **Coisa Temporal (*TemporalThing*):** Classe subdividida em duas subclasses, Instante (*Instant*) e Intervalo (*Interval*), conforme ilustrado na figura 34. Um instante é um ponto específico no tempo, enquanto um intervalo é uma janela de tempo composto por um instante inicial e um final.
- **Contexto (*Context*):** Classe que representa o contexto do modelo, e é composta pelas seguintes classes: (1) uma pessoa, (2) um ou mais eventos com diagnósticos atribuídos a pessoa, (3) uma coisa temporal, (4) uma ou mais coisas espaciais, (5) uma informação de comportamento e sensoriamento.
- **Histórico de Contexto (*ContextHistory*):** Classe composta por múltiplos contextos de uma determinada pessoa ao longo do tempo.

Figura 34: Visão detalhada das classes que definem tempo e espaço



Fonte: Elaborado pelo autor.

5 AVALIAÇÃO

A seção anterior apresentou o modelo Eigenroutines, e detalhou a forma como o processo e o algoritmo de comparação de históricos de contextos deve ser utilizado para identificar rotinas comportamentais de indivíduos ou grupos, enquanto esta seção apresenta a validação do modelo em duas etapas distintas visando responder cada uma das questões gerais de pesquisa apresentadas na seção 1.2.

5.1 Metodologia de avaliação

As avaliações apresentadas nesta seção estão divididas em três análises: (1) avaliação do algoritmo, (2) avaliação dos perfis epidemiológicos e (3) avaliação e discussão da escalabilidade de inferência da ontologia proposta.

A primeira avaliação tem por objetivo confirmar que o modelo e algoritmos do Eigenroutines detalhados na seção 4 tem a capacidade de: (1) identificar e distinguir padrões comportamentais em indivíduos saudáveis e com transtornos neuropsiquiátricos a partir de um histórico de contextos, e (2) identificar uma mudança no padrão comportamental que aproxime um indivíduo do grupo saudável quando comparado ao grupo diagnosticado com um transtorno neuropsiquiátrico.

Para realizar tal avaliação se fez o uso de uma base de dados contendo dados de actigrafia de pessoas com depressão, e se comparou diferentes algoritmos classificadores entre si e em relação ao modelo apresentado pelos autores da base de dados.

Uma vez avaliada a condição do modelo de comparar padrões comportamentais, é possível responder a primeira questão geral de pesquisa: “Como deve ser um modelo computacional para identificar padrões comportamentais em indivíduos com transtornos neuropsiquiátricos a partir do histórico de contextos de forma a suportar o tratamento e acompanhamento de outros indivíduos?”.

A segunda avaliação tem por objetivo mapear e apresentar perfis epidemiológicos extraídos a partir dos históricos de contextos armazenados pela plataforma com objetivo de responder a segunda questão geral de pesquisa: “É possível utilizar esse modelo de auxílio de indivíduo para construção de perfis epidemiológicos de transtornos neuropsiquiátricos?”.

Para a segunda avaliação foi realizada uma simulação da utilização do modelo para extração de perfis epidemiológicos, sendo que os dados simulados foram baseados em estudos anteriores realizados no Brasil de perfis epidemiológicos para transtornos neuropsiquiátricos.

A última avaliação complementa a segunda avaliação e discute as limitações e necessidade de escala para tal abordagem, utilizando uma extrapolação dos dados simulados na segunda avaliação para identificar potenciais problemas de escalabilidade.

5.2 Identificação de padrões de atividade em pessoas com depressão utilizando actigrafia

Para a primeira avaliação foram utilizados os dados disponibilizados por Garcia-Ceja et al. (GARCIA-CEJA *et al.*, 2018), composto pelo acompanhamento de indivíduos utilizando um dispositivo vestível chamado *Actiwatch* vestido no pulso. Este dispositivo tem a capacidade

de coletar informações sobre a frequência de movimentação quando a intensidade do movimento é acima de 0.05g.

Os dados de atividade foram coletados em 55 indivíduos, sendo este grupo composto de 23 pessoas com depressão unipolar ou bipolar e 32 pessoas saudáveis. Para a avaliação clínica dos indivíduos com depressão se utilizou o questionário *Montgomery-Asberg Depression Rating Scale* (MONTGOMERY; ASBERG, 1979), também conhecido como MADRS, e as avaliações dos indivíduos com depressão foram realizadas uma antes e outra após o período de acompanhamento.

Os dispositivos foram utilizados em média por 12 dias pelos indivíduos e no total foram coletados 693 dias com entradas minuto a minuto, totalizando pouco menos de 998 mil registros de atividade. Antes de serem disponibilizados para a comunidade acadêmica os dados foram anonimizados e informações, como por exemplo o dia da atividade, foram alterados para evitar a possibilidade de identificação dos participantes.

Considerando esse grupo de dados as duas características do modelo, ou seja, a condição de classificar um indivíduo baseado no padrão de comportamento e a condição de identificar a proximidade do comportamento de um indivíduo entre grupos foram validadas.

A primeira questão foi validada a partir da identificação da acurácia do modelo utilizando algoritmos clássicos de classificação supervisionada, testado utilizando *5-fold cross-validation*, para avaliar se a modelagem de rotina tem algum ganho em relação à avaliação do trabalho de Garcia-Ceja et. al. (GARCIA-CEJA *et al.*, 2018), bem como isolar e avaliar a capacidade do modelo de identificar rotinas.

A segunda questão foi validada a partir da escolha do indivíduo com a maior melhoria na avaliação MADRS para verificar se o algoritmo de cálculo de distância entre rotina seria capaz de identificar a mudança no comportamento se distanciando de indivíduos com depressão e se aproximando do grupo de indivíduos saudáveis.

5.2.1 Parâmetros e algoritmos no modelo

Uma vez que o ambiente disponível no modelo influencia diretamente na determinação dos indicadores, se faz necessário definir quais dispositivos e quais algoritmos estão disponíveis para uso do mesmo. Em ambas as avaliações, o modelo foi avaliado com a seguinte configuração:

- Lista de dispositivo disponíveis: Actiwatch;
 - Capacidades do dispositivo: Acelerômetro;
- Avaliação profissional preliminar dos indivíduos com depressão: Transtorno depressivo maior recorrente (DSM-V 296.3x, ICD F33);
- Repositório de indicadores disponível: Actigrafo em janelas de minuto a minuto;
 - Requisito de sensor: Acelerômetro;

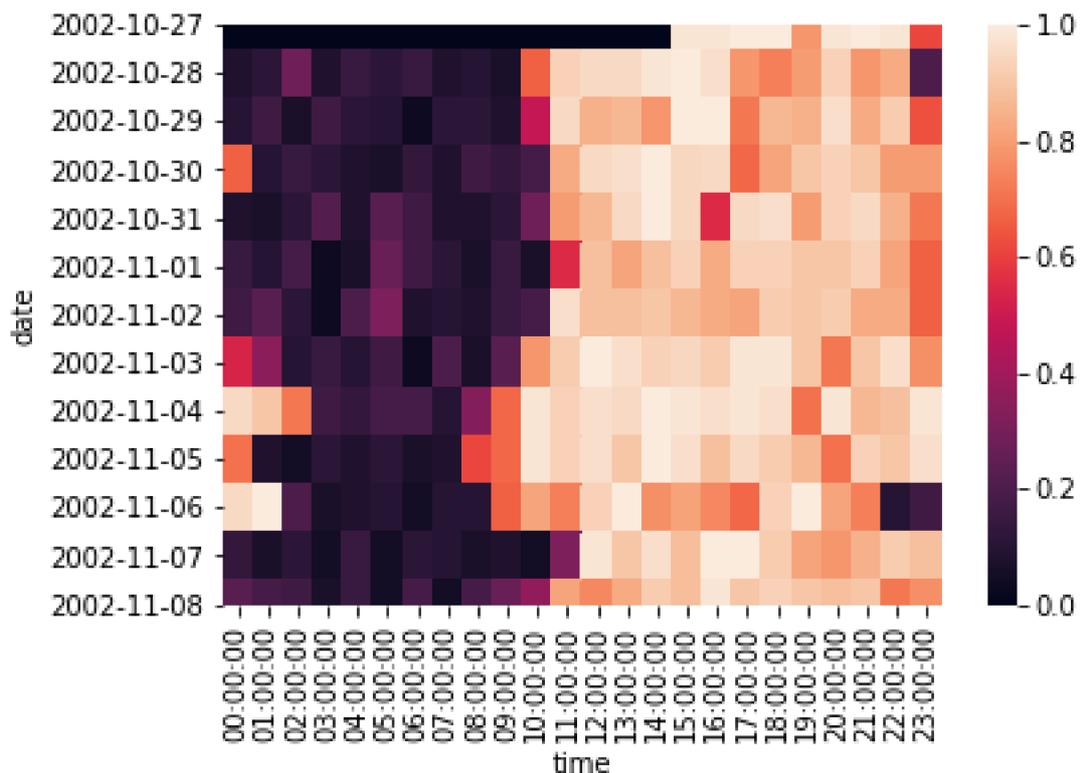
Sendo que o algoritmo de transformação dos dados de sensoriamento em indicador do actigrafo é dado como:

- (1) a soma de toda leitura do acelerômetro a cada minuto, e se a mesma for superior ao ruído (determinado como “4”), então o minuto é considerado ativo (1), senão o minuto é considerado inativo (0).
- (2) Os dados de cada minuto são agregados em janela de horas, sendo que o valor máximo de cada janela é 60 (ativo em todos os minutos), e o mínimo é 0 (inativo em todos os minutos).

Este algoritmo implementa a transformação $f_i(s)$ ilustrada no modelo pela figura 27, e aplicando o conceito básico de sensoriamento apresentado na seção 4.1, cujo objetivo essencial é transformar dados de um sensor de dispositivo móvel em vestível em uma informação que possa ser armazenada como parte de um contexto.

Após o processamento dos dados pela função $f_i(s)$ é possível extrair os parâmetros t e i do contexto c conforme o modelo ilustrado pela figura 27 formando um histórico de contextos, e ilustrar em forma de mapa de calor onde as linhas representam os dias e as colunas representam as janelas de hora, e o conteúdo do indicador i é representado por uma intensidade de cor, onde áreas do gráfico mais escuras correspondem valores de atividade próximos a 0 e áreas mais claras no gráfico representando períodos mais intensos de atividade contínua.

Figura 35: Ilustração do parâmetro i por cada janela de tempo t para o indivíduo de controle #4



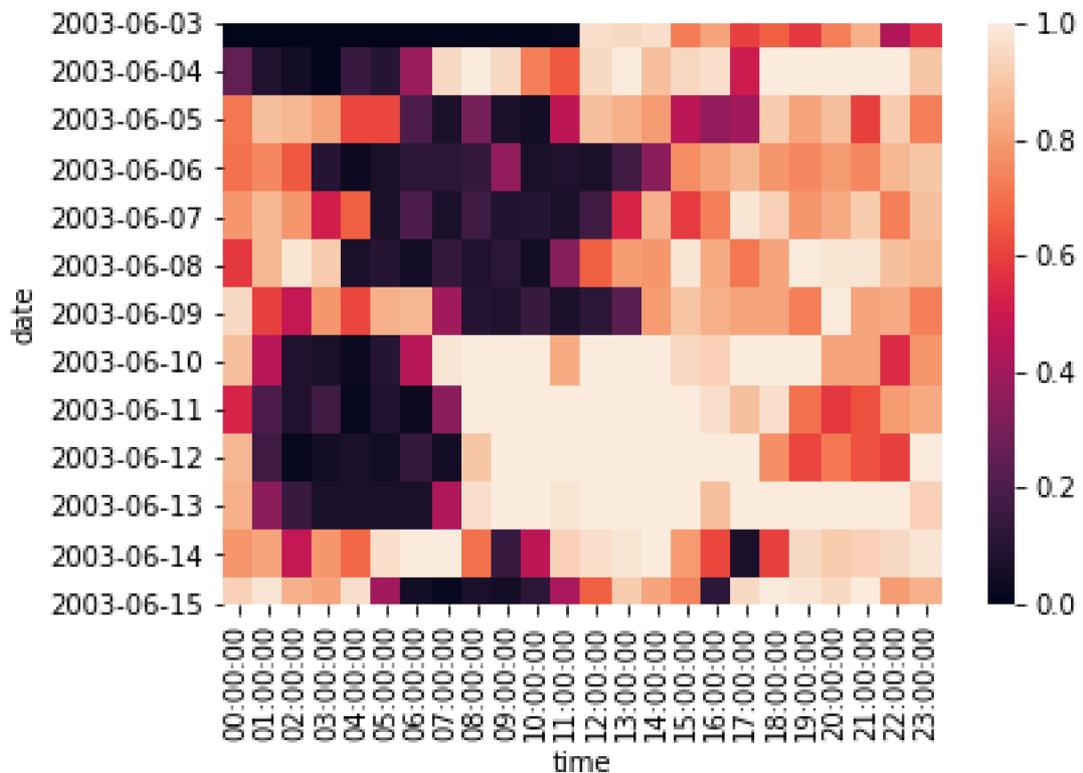
Fonte: Elaborado pelo autor.

A figura 35 ilustra o contexto formado pelo indicador de intensidade de atividade para o indivíduo de controle número 4, onde é possível observar que os períodos de maior atividade é entre as 9 e 23 horas do dia. Neste mapa de calor, cada linha corresponde a um dia e cada coluna corresponde a uma hora do dia. A intensidade de cada célula é definida pelo algoritmo do indicador, que define a quantidade de minutos de atividade dentro daquela hora, podendo

variar de 0 a 60. A coloração mais escura representa janelas de hora sem atividade, ou seja, com movimentação mínima do actígrafo, enquanto a coloração mais clara representa janelas de hora com atividade.

A figura 36 ilustra o mesmo indicador para o indivíduo com depressão número 4. Somente a partir dessa ilustração já é possível identificar uma variação de comportamento do indivíduo com depressão, especialmente durante a madrugada, bem como períodos de intensa movimentação.

Figura 36: Ilustração do parâmetro i por cada janela de tempo t para o indivíduo com depressão #4



Fonte: Elaborado pelo autor.

5.2.2 Identificação de rotinas

Após o processo de computar e armazenar o contexto é realizado o processo de identificação de rotinas nestes contextos seguindo o conceito de comparação apresentado na seção 4.1. Conforme apresentado na seção anterior, na primeira avaliação o histórico de contexto é formado por uma variável contínua e o padrão de comportamento é extraído conforme algoritmo explicado na seção 4.5.

Para cada indivíduo o seguinte processamento é aplicado:

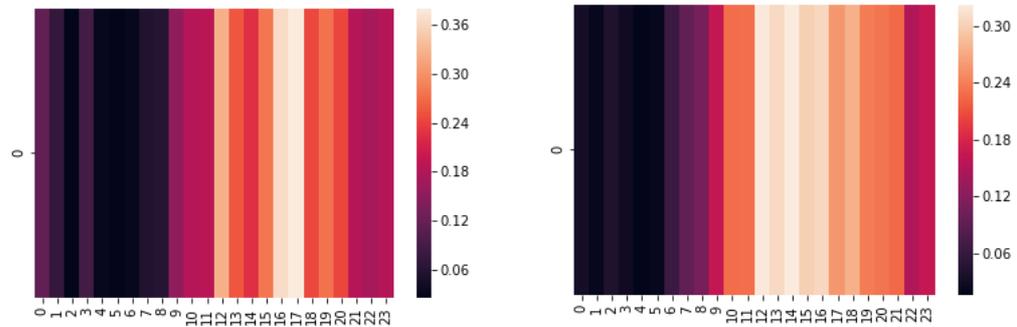
- Para cada hora do dia, cada registro contínuo é normalizado entre valores de -1 a 1 utilizando a fórmula Φ_c apresentada na seção 4.5.

- Cada registro discreto é normalizado contra a média do mesmo registro, utilizando a fórmula Φ_d apresentada na seção 4.5.
- Os Eigen vetores são extraídos via Eigen-decomposição matriz Φ por análise de componentes principais, e os dois componentes mais relevantes são utilizados como identificadores de rotina.

O resultado dessa transformação são dois vetores que em média identificam 70% da variância no comportamento de um indivíduo, dependendo da entropia de cada pessoa, e para fins de comparação de contexto estes dois vetores são considerados o resumo da rotina de um indivíduo dado seu contexto c .

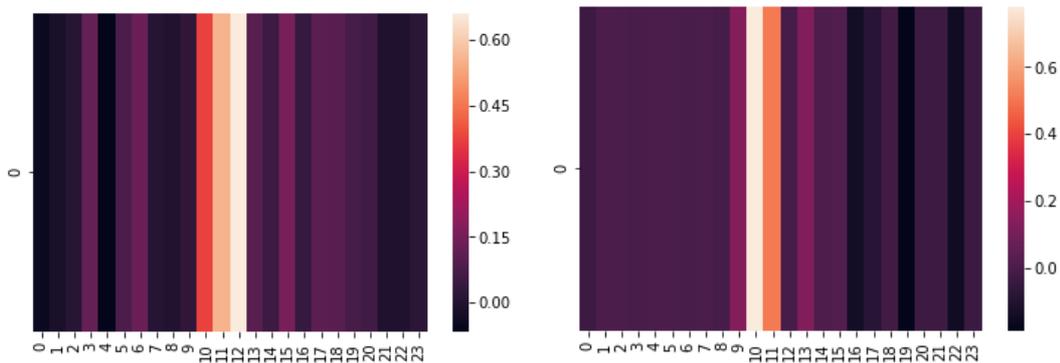
A figura 37 ilustra estes vetores para dois indivíduos de controle, enquanto a figura 38 ilustra o resultado computado para dois indivíduos com depressão.

Figura 37: Representação gráfica do primeiro *eigenbehavior* para os indivíduos de controle #3 e #4



Fonte: Elaborado pelo autor.

Figura 38: Representação gráfica do primeiro *eigenbehavior* para indivíduos com depressão #3 e #4



Fonte: Elaborado pelo autor.

5.2.3 Comparação de rotinas

Após a extração da rotina em forma de vetor o indivíduo é classificado de acordo com uma escolha adaptativo de algoritmo de classificação. A abordagem adaptativa deriva do modelo ORACON (DA ROSA; BARBOSA; RIBEIRO, 2016), onde o modelo propõe uma abordagem adaptativa na escolha de algoritmos para predição de contexto, e nesta implementação do modelo é utilizado para escolha dos classificadores.

Para fins desta avaliação os classificadores escolhidos foram baseados nos classificadores identificados na seção 3.13 ou um algoritmo semelhantes disponível no pacote *sklearn*:

- *K-Nearest Neighbors*, parametrizado para 6 observações vizinhas;
- Máquina de vetores de suporte (SVM), parametrizado com algoritmo de treinamento linear e parâmetro de regularização definido como “5”;
- Árvore de decisão com profundidade 11;
- *Random forests* com profundidade 11 e 100 árvores;
- Redes neurais *Multi-Layer Perceptron* com 100 camadas escondidas;
- *AdaBoost SAMME* com árvore de decisão como classificador base;
- *Gaussian Naive Bayes*;
- Processo gaussiano com algoritmo de treinamento de função de base radial.

A tabela 8 apresenta a acurácia média e desvio-padrão para a validação cruzada com método *k-fold* dividindo os dados em 5 subconjuntos.

A linha da tabela apresentado o classificador de “maior frequência” equivale a uma classificação fixa onde todos os elementos sempre são atribuídos para a categoria de maior frequência, que para este conjunto de dados é a classe de “controle”.

Tabela 8: Comparação da acurácia de cada classificador

| Classificador | Acurácia média | Desvio-padrão |
|--|-----------------------|----------------------|
| <i>K-Nearest Neighbors</i> | 66% | 8% |
| Máquina de vetores de suporte (<i>SVM</i>) | 75% | 13% |
| Árvore de decisão | 72% | 7% |
| <i>Random forests</i> | 76% | 6% |
| Redes neurais (<i>MLP</i>) | 75% | 14% |
| <i>AdaBoost</i> | 74% | 9% |
| <i>Gaussian Naive Bayes</i> | 78% | 3% |
| Processo gaussiano | 70% | 7% |
| Maior frequência | 59% | 2% |

Fonte: Elaborado pelo autor.

É possível observar uma alta acurácia nos algoritmos *Random Forest* e *Naive Bayes*, com resultados superiores aos apresentados no trabalho de Garcia-Ceja et. al. (GARCIA-CEJA et al., 2018) cuja melhor acurácia foi de 72.7%, sem apresentar desvio padrão.

Considerando que a modelagem do problema em relação a intensidade de atividades é semelhante ao trabalho de Garcia-Ceja et. al. (GARCIA-CEJA et al., 2018), é possível verificar que a extração das rotinas utilizando o modelo *Eigenroutine* é superior na identificação de transtornos em relação a comparação de contextos sem a definição de um *eigenbehavior*.

Ou seja, em um contexto modelado a partir do indicador de intensidade de atividade com uma variável contínua, o modelo apresentou uma acurácia de 78% para classificar a rotina de um indivíduo entre depressivo e saudável.

5.2.4 Cálculo de distância entre rotinas

A seção anterior apresentou o resultado dos classificadores e a capacidade do modelo em extrair uma rotina de um histórico de contextos e comparar rotinas para classificar um indivíduo em uma categoria conhecida.

A segunda avaliação consiste em verificar a capacidade do modelo em identificar o “movimento” da rotina de um indivíduo no espaço de comportamento, se distanciando do comportamento depressivo e se aproximando do comportamento saudável.

Para tal avaliação foi selecionado o indivíduo com depressão #2, cuja avaliação MADRS no início da avaliação foi estimada em 24 pontos (depressão moderada) e ao final da avaliação foi estimada em 11 pontos (depressão leve, próximo ao limiar de saudável).

O indivíduo com depressão #2 é um homem, solteiro, com idade entre 40 e 44 anos que foi acompanhado por 18 dias, diagnosticado com transtorno bipolar II.

Para fins desta avaliação o modelo foi carregado com todos os indivíduos com exceção do indivíduo com depressão #2. Em seguida os dados dos primeiros 9 dias do indivíduo com depressão #2 foram carregados e distância média para cada um dos grupos foi calculada. Por fim os últimos 9 dias foram carregados e a distância média calculada.

Para o cálculo de distância, cada indivíduo disponível na base dados teve seu comportamento projetado contra o comportamento médio do grupo (ω_k^i), e a distância calculada como a distância euclidiana entre os *eigenbehaviors* das duas projeções, conforme detalhado na seção 4.5.1.

A tabela 9 apresenta o resumo das distâncias entre rotinas dos indivíduos do grupo de controle e do grupo com depressão.

É possível observar na coluna da primeira metade que durante os primeiros 9 dias de acompanhamento do indivíduo com depressão #2 o mesmo ficou a uma distância menor dos outros 22 indivíduos com depressão se comparado à distância dos 32 indivíduos do grupo de controle.

Na coluna da segunda metade de acompanhamento, ou seja, entre o 10° e o 18° dia em que o indivíduo com depressão #2 foi acompanhado demonstrou uma movimentação de sua rotina se afastando do grupo de indivíduos com depressão e se aproximando do grupo de indivíduos de controle. Desta forma é possível verificar que o cálculo de distância do modelo é

capaz de identificar a proximidade de rotinas em um indivíduo que apresentou melhorias consideráveis em seu diagnóstico clínico.

Tabela 9: Comparação da distância da rotina entre o indivíduo com depressão #2 e os demais indivíduos.

| | Primeira Metade | Segunda Metade |
|---|------------------------|-----------------------|
| Distância para indivíduos do grupo com depressão | | |
| Total de registros comparados | 22 | 22 |
| Média | 1.853628 | 2.007097 |
| Desvio-padrão | 0.485441 | 0.208242 |
| Distância para indivíduos do grupo de controle | | |
| Total de registros comparados | 32 | 32 |
| Média | 2.142374 | 1.592183 |
| Desvio-padrão | 0.415020 | 0.412471 |

Fonte: Elaborado pelo autor.

5.3 Construção do perfil epidemiológico baseado na confirmação do diagnóstico

A segunda avaliação visa validar se a ontologia proposta na seção 4.8 e os conceitos apresentados na seção 4.3 possibilitam a construção de perfis epidemiológicos baseados nas informações obtidas pelo modelo Eigenroutines. Um perfil epidemiológico é um indicador observacional das condições sociodemográficas e visa suportar trabalhos de investigação epidemiológica bem como a construção de políticas de saúde pública a partir da análise dos grupos e dos fatores de risco associados a determinados transtornos.

Para tal avaliação, se determinou as seguintes questões de competência, adotadas a partir das observações de perfis epidemiológicos de transtornos neuropsiquiátricos publicados na literatura médica brasileira (ARAÚJO *et al.*, 2019; BAASCH; TREVISAN; CRUZ, 2017; DALARMELINA; ALMANÇA; OLIVEIRA-CORTEZ, 2017; LAURINDO; LOPES; ROCHA, 2020):

- **QC1:** Qual a situação sociodemográfica para casos de depressão observado durante o período do experimento?
- **QC2:** Quantos casos incidentes foram identificados durante o período do experimento?
- **QC3:** Existe alguma comorbidade identificada no experimento?
- **QC4:** Qual a medicação mais comum utilizada para depressão profunda?
- **QC5:** Qual medicação com maior taxa de remissão para o período do estudo?

O modelo então é considerado apto a construir perfis epidemiológicos se o mesmo for capaz de responder a estas questões de competência através de inferências na ontologia proposta.

Para responder estas perguntas foram utilizados dois grupos distintos de informações, sendo o primeiro realizado com base no grupo de dados utilizados na avaliação apresentada na seção 5.2 compartilhado por Garcia-Ceja et. al. (GARCIA-CEJA *et al.*, 2018) sem modificações para responder a primeira questão (QC1), e o segundo baseado em uma simulação de 1065 indivíduos utilizando os percentuais reportados pelos trabalhos de referência em perfis epidemiológicos (ARAÚJO *et al.*, 2019; BAASCH; TREVISAN; CRUZ, 2017; DALARMELINA; ALMANÇA; OLIVEIRA-CORTEZ, 2017; LAURINDO; LOPES; ROCHA, 2020) como representativos da população simulada nas respectivas regiões, e o resultado de tal simulação é utilizado para responder as questões QC2 a QC5.

5.3.1 Expressão de busca e resultado a questão de competência QC1

A figura 39 ilustra as expressões de busca SPARQL utilizadas para extrair os dados sociodemográficos para os casos incidentes de depressão profunda por sexo e faixa etária que resultaram nos casos apresentados na tabela 10, onde é possível notar que, apesar do pequeno volume de informações, a maioria dos casos identificados neste grupo são de homens da faixa etária adulta.

Tabela 10: Casos de depressão por faixa etária e sexo nos dados de (GARCIA-CEJA *et al.*, 2018)

| Faixa etária | Sexo | Número de casos |
|-----------------------------|----------------------------|-----------------|
| Adulto (<i>Adult</i>) | Masculino (<i>Male</i>) | 13 |
| Adulto (<i>Adult</i>) | Feminino (<i>Female</i>) | 8 |
| Jovem (<i>YoungAdult</i>) | Feminino (<i>Female</i>) | 1 |
| Idoso (<i>Elderly</i>) | Feminino (<i>Female</i>) | 1 |

Fonte: Elaborado pelo autor.

Figura 39: Expressão da busca SPARQL para identificação casos de depressão profunda por sexo e faixa etária

```
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX e: <http://www.unisinos.br/pipca/ontologies/eroutines#>

SELECT ?gender ?ageGroup ( COUNT(?person) as ?personcount )
WHERE {
  ?assessment e:hasSociodemographicProfile ?sociodemprof .
  ?assessment e:hasDiagnosis ?diagnosis .
  ?assessment e:belongsToContext ?context .
  ?diagnosis a e:NewDiagnosis .
  ?diagnosis a e:ConfirmedDiagnosis .
  ?diagnosis e:hasDisorder ?disorder .
  ?disorder a e:MajorDepression .
  ?sociodemprof a e:SociodemographicProfile .
  ?sociodemprof e:gender ?gender .
  ?sociodemprof rdfs:type ?ageGroup .
  ?ageGroup rdfs:subClassOf e:AgeGroup .
  ?context e:happenedWithPerson ?person .
  FILTER( ?ageGroup != e:AgeGroup ) .
}
GROUP BY ?gender ?ageGroup ORDER BY DESC(?personcount)
```

Fonte: Elaborado pelo autor.

Neste processo de busca as classes de faixas etárias, tipos de diagnósticos e transtorno são inferidas utilizando o motor de inferência Hermit (GLIMM *et al.*, 2014) baseado nos atributos de idade, estado do diagnóstico e código DSM-5 do transtorno.

A maioria das expressões de buscas apresentadas nesta avaliação foram executadas utilizando o Snap SPARQL do ambiente Protegè, com exceção da expressão da questão de competência 5 que foi executada no banco de dados Virtuoso devido à complexidade da expressão.

A tabela 11 apresenta os axiomas de equivalência utilizados para inferência de faixa etária e classe de transtorno utilizados pela expressão ilustrada na figura 39, onde os atributos de idade e código DSM-5 são utilizados de forma a inferir as classes corretas para um determinado perfil sociodemográfico e transtorno neuropsiquiátrico.

Tabela 11: Axiomas de equivalência para classes inferidas

| Classe | Axioma de Equivalência | Descrição |
|-----------------------------------|---|---|
| <i>Elderly</i> | AgeGroup and (age some xsd:int[>= "60"^^xsd:int]) | Classe de faixa etária para Idosos, maior que 60 anos, pode ser atribuída a uma pessoa ou perfil sociodemográfico. |
| <i>Adult</i> | AgeGroup and (age some xsd:int[>= "25"^^xsd:int , < "60"^^xsd:int]) | Classe de faixa etária para Adultos, de 25 a 60 anos, pode ser atribuída a uma pessoa ou perfil sociodemográfico. |
| <i>Young Adult</i> | AgeGroup and (age some xsd:int[>= "18"^^xsd:int , < "25"^^xsd:int]) | Classe de faixa etária para Jovens adultos, de 18 a 25 anos, pode ser atribuída a uma pessoa ou perfil sociodemográfico. |
| <i>Teenager</i> | AgeGroup and (age some xsd:int[>= "13"^^xsd:int , < "18"^^xsd:int]) | Classe de faixa etária para Adolescentes, de 13 a 18 anos, pode ser atribuída a uma pessoa ou perfil sociodemográfico. |
| <i>Children</i> | AgeGroup and (age some xsd:int[< "13"^^xsd:int]) | Classe de faixa etária para Crianças, menor de 13 anos, pode ser atribuída a uma pessoa ou perfil sociodemográfico. |
| <i>Recurrent Major Depression</i> | Disorder and (icd11code value "F33" or dsm5code value "296.3x") | Classe para transtorno depressivo maior em episódios recorrentes, subclasse de <i>MajorDepression</i> |
| <i>Single Major Depression</i> | Disorder and (icd11code value "F32" or dsm5code value "296.2x") | Classe para transtorno depressivo maior em episódio único (e.g. Depressão pós-parto), subclasse de <i>MajorDepression</i> |
| <i>General Anxiety</i> | Disorder and (icd11code value "F41" or dsm5code value "300.xx") | Classe para transtorno de ansiedade generalizada, subclasse de <i>Anxiety</i> |

A tabela 12 apresenta o resultado de outra expressão de busca SPARQL para contabilizar os casos de depressão por escolaridade, estado civil e situação empregatícia, podendo se observar que da população acompanhada a maioria tem o ensino médio completo, que o número de casos entre solteiros e casados está bem distribuído e que a maioria dos pacientes está em licença por doença.

Tabela 12: Casos de depressão por escolaridade, estado civil e situação empregatícia em relação aos dados de (GARCIA-CEJA *et al.*, 2018)

| Característica | Número de casos |
|------------------------------|------------------------|
| Escolaridade | |
| Ensino médio completo | 12 |
| Ensino superior completo | 8 |
| Pós-graduação completa | 2 |
| Ensino fundamental completo | 1 |
| Estado civil | |
| Solteiro(a) | 12 |
| Casado(a) | 11 |
| Situação empregatícia | |
| Licença por doença | 20 |
| Empregado | 3 |

Fonte: Elaborado pelo autor.

5.3.2 Distribuição e características dos pacientes simulados para questões de competência QC2 a QC5

A segunda etapa da avaliação simula o processo de diagnóstico e confirmação, conforme conceitos da seção 4.1, para 1066 indivíduos utilizando como base os trabalhos de referência utilizados para definição das questões de competência.

Para isso foram simulados indivíduos conforme apresentado na tabela 13, onde é possível verificar que os pacientes foram distribuídos em 50% dos casos diagnosticados em 2019 e 50% em 2020, e que três grupos foram simulados divididos por estado: Ceará, Minas Gerais e Bahia.

Tabela 13: Lista de pacientes simulados por região e data

| Característica | Número de casos |
|-----------------------|------------------------|
| Grupos/Local | |
| Morrinhos/CE | 73 |
| Itajubá/MG | 963 |
| Salvador/BA | 30 |
| Período | |
| Nov a Dez/2019 | 533 |
| Jan a Fev/2020 | 533 |

Fonte: Elaborado pelo autor.

Os indivíduos simulados em Morrinhos no Ceará foram baseados no trabalho de (LAURINDO; LOPES; ROCHA, 2020), dos quais 73 idosos foram simulados com transtorno depressivo maior, seguindo a distribuição apresentada na tabela 14.

Tabela 14: Distribuição de características dos pacientes em Morrinhos

| Característica | Percentual de pacientes |
|-------------------------|--------------------------------|
| Sexo | |
| Masculino | 65.27% |
| Feminino | 34.73% |
| Idade | |
| 65 | 51% |
| 75 | 31% |
| 85 | 18% |
| Estado Civil | |
| Casado(a) | 31.94% |
| Solteiro(a) | 2.77% |
| Divorciado(a) | 2.77% |
| Viúvo(a) | 62.52% |
| Escolaridade | |
| Nunca estudou | 37.50% |
| Fundamental incompleto | 38.88% |
| Ensino médio completo | 15.27% |
| Curso superior completo | 8.35% |

Emprego

| | |
|--------------|--------|
| Dona de casa | 22.22% |
| Autônomo | 30.55% |
| Aposentado | 47.23% |

Transtorno

| | |
|--|------|
| Transtorno depressivo maior recorrente | 100% |
|--|------|

Fonte: Elaborado pelo autor.

Para os pacientes de Itajubá em Minas Gerais, 963 indivíduos foram simulados com base em (DALARMELINA; ALMANÇA; OLIVEIRA-CORTEZ, 2017), onde 315 foram simulados com depressão, 532 com ansiedade generalizada e 116 com comorbidade de ansiedade generalizada e depressão profunda. A taxa de comorbidade foi estimada em 12% baseada em (MOFFITT *et al.*, 2007) uma vez que a mesma não foi apresentada no trabalho original. A tabela 15 apresenta os critérios de distribuição dos indivíduos por grupo de transtorno, como o percentual de indivíduos por sexo, idade, estado civil, escolaridade, emprego e medicação.

Tabela 15: Distribuição de características simuladas por grupo de transtorno dos pacientes de Itajubá

| Característica | Grupo com Depressão | Grupo com Ansiedade | Grupo com Comorbidade |
|-----------------------|----------------------------|----------------------------|------------------------------|
| Sexo | | | |
| Masculino | 34.08% | 36.69% | 35.72% |
| Feminino | 65.92% | 63.31% | 64.28% |
| Idade | | | |
| 18 | 10.86% | 10.02% | 10.33% |
| 22 | 12.29% | 13.36% | 12.96% |
| 35 | 17.14% | 17.40% | 17.30% |
| 45 | 20.00% | 22.14% | 21.35% |
| 55 | 18.57% | 19.68% | 19.27% |
| 65 | 21.14% | 17.40% | 18.79% |
| Estado Civil | | | |
| Casado(a) | 36.92% | 40.22% | 38.99% |
| Solteiro(a) | 53.85% | 47.83% | 50.06% |
| Divorciado(a) | 6.15% | 5.43% | 5.70% |
| Viúvo(a) | 1.54% | 5.43% | 3.99% |
| União estável | 1.54% | 1.09% | 1.25% |

| | | | |
|--|--------|--------|--------|
| Escolaridade | | | |
| Desconhecido | 100% | 100% | 100% |
| Emprego | | | |
| Dona de casa | 37.10% | 26.74% | 30.59% |
| Estudante | 16.13% | 30.23% | 24.99% |
| Aposentado | 8.06% | 6.98% | 7.38% |
| Empregado | 38.71% | 36.05% | 37.04% |
| Transtorno | | | |
| Transtorno depressivo maior recorrente | 100% | | 100% |
| Transtorno de ansiedade generalizada | | 100% | 100% |
| Medicação | | | |
| Clonazepam | 29.17% | 29.17% | 29.17% |
| Sertralina | 25.05% | 25.05% | 25.05% |
| Fluoxetina | 17.73% | 17.73% | 17.73% |
| Escitalopram | 15.06% | 15.06% | 15.06% |
| Diazepam | 12.99% | 12.99% | 12.99% |

Fonte: Elaborado pelo autor.

Em Salvador na Bahia foram simulados 30 pacientes com base em (ARAÚJO *et al.*, 2019), todos os pacientes são mulheres jovens apresentando depressão pós-parto, ao qual se utilizou a definição de episódio único de transtorno depressivo maior conforme o DSM-5.

O objetivo de utilizar um transtorno distinto foi a necessidade de avaliar a capacidade do modelo de generalizar conceitos a partir de inferência, como por exemplo agrupar episódios de depressão maior recorrente e único em um grupo, bem como de ser capaz de apresentar dados epidemiológicos no nível mais granular disponível.

Para fins de possibilitar a avaliação da questão de competência 5 foi determinada a probabilidade de 50% para remissão dos pacientes simulados em Itajubá e de Salvador em até 3 meses após a incidência.

A tabela 16 apresenta as características utilizadas para simulação dos pacientes de Salvador, onde as medicações atribuídas foram estimadas com base nas informações disponibilizadas em (DALARMELINA; ALMANÇA; OLIVEIRA-CORTEZ, 2017) porém restrita a medicações com baixo risco de interferência na amamentação. Devido a falta de informação de medicação foi assumido também que um grupo de 42% dos pacientes simulados não está fazendo uso de nenhum fármaco.

Tabela 16: Distribuição de características simuladas dos pacientes de Salvador

| Característica | Percentual de pacientes |
|---|--------------------------------|
| Sexo | |
| Feminino | 100% |
| Idade | |
| 17 | 16.67% |
| 23 | 46.67% |
| 35 | 36.66% |
| Estado Civil | |
| Casado(a) | 16.67% |
| Solteiro(a) | 43.33% |
| União Estável | 40.00% |
| Escolaridade | |
| Nunca estudou | 3.33% |
| Fundamental incompleto | 13.33% |
| Fundamental completo | 6.67% |
| Ensino médio incompleto | 23.33% |
| Ensino médio completo | 50.00% |
| Curso superior incompleto | 3.34% |
| Emprego | |
| Dona de casa | 50.00% |
| Empregado | 23.33% |
| Estudante | 13.33% |
| Desempregado | 13.33% |
| Transtorno | |
| Transtorno depressivo maior de episódio único com início no parto | 100% |
| Medicação | |
| Sertralina | 25.05% |
| Fluoxetina | 17.73% |
| Escitalopram | 15.06% |
| Sem medicação | 42.16% |

Fonte: Elaborado pelo autor.

5.3.3 Expressões de busca e respostas para questões de competência QC2 a QC5

Para responder a segunda questão de competência (QC2) a expressão de busca ilustrada na figura 40 foi utilizada, restringindo os perfis sociodemográficos (restrição 1 da figura) em diagnósticos novos e confirmados (restrição 2 da figura) em um determinado contexto (restrição 3 da figura) onde o agrupamento é realizado baseado no ano em que o contexto, e por consequência a avaliação, foi realizada.

O resultado está apresentado na figura 40, sendo uma divisão de 50% dos casos em 2019, e 50% dos casos em 2020, conforme apresentado nos dados simulados da tabela 13, sendo o indivíduo a mais em 2020 causado pela distribuição dos 73 idosos de Morrinhos entre as duas datas.

A resposta para segunda questão de competência para os dados simulados é de que em 2020 foram 592 casos, sendo 324 casos de ansiedade e 268 casos de depressão profunda.

Figura 40: Expressão de busca para contagem de casos incidentes por ano por transtorno

```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX m: <http://www.unisinos.br/pipca/ontologies/eroutines#>

SELECT ?year ?disorder ( COUNT(?diagnosis) as ?cases )
WHERE {
  ?assessment m:hasSociodemographicProfile ?sociodemprof ;
              m:hasDiagnosis ?diagnosis ;
              m:belongToContext ?context .
  ?diagnosis a m:NewDiagnosis ;
              a m:ConfirmedDiagnosis ;
              m:hasDisorder ?disorder .
  ?context m:happenedWithPerson ?person ;
           m:happenedOn ?date .
  BIND(YEAR(?date) AS ?year) .
}
GROUP BY ?year ?disorder ORDER BY DESC(?cases)

```

Execute

| ?year | ?disorder | ?cases |
|-------|---|--------|
| 2020 | m:Disorder-General-Anxiety | 324 |
| 2019 | m:Disorder-General-Anxiety | 324 |
| 2020 | m:Disorder-Recurrent-Major-Depression | 253 |
| 2019 | m:Disorder-Recurrent-Major-Depression | 251 |
| 2019 | m:Disorder-PostPartum-Single-Episode-Depression | 15 |
| 2020 | m:Disorder-PostPartum-Single-Episode-Depression | 15 |

A expressão ilustrada pela figura 41 foi utilizada para responder a terceira questão de competência (QC3), onde a cláusula de restrição busca por avaliações médicas (restrições 1 e 4 da figura) que pertencem a mesma pessoa (restrições 3 e 5) com transtornos distintos (restrições 2, 6 e 7). O resultado da busca resultou em 116 casos comorbidos de ansiedade generalizada e depressão maior, respondendo a terceira questão conforme o esperado.

Figura 41: Expressão de busca SPARQL para identificação de comorbidades

```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX m: <http://www.unisinos.br/pipca/ontologies/eroutines#>

SELECT ?disorderA ?disorderB ( COUNT(?person) as ?peopleCount )
WHERE {
  ?assessment m:hasDiagnosis ?diagnosis ;                               1
             m:belongsToContext ?diagnosisContext .

  ?diagnosis a m:NewDiagnosis ;                                       2
             a m:ConfirmedDiagnosis ;
             m:hasDisorder ?disorderA .

  ?diagnosisContext m:happenedWithPerson ?person .                    3

  ?anotherAssessment m:hasDiagnosis ?anotherDiagnosis ;              4
                    m:belongsToContext ?anotherDiagnosisContext .

  ?anotherDiagnosisContext m:happenedWithPerson ?person .           5

  ?anotherDiagnosis m:hasDisorder ?disorderB ;                       6
                    a m:ConfirmedDiagnosis .

  FILTER(?disorderA != ?disorderB).                                  7
}
GROUP BY ?disorderA ?disorderB ORDER BY DESC(?peopleCount)

```

Execute

| ?disorderA | ?disorderB | ?peopleCount |
|---------------------------------------|---------------------------------------|--------------|
| m:Disorder-General-Anxiety | m:Disorder-Recurrent-Major-Depression | 116 |
| m:Disorder-Recurrent-Major-Depression | m:Disorder-General-Anxiety | 116 |

Fonte: Elaborado pelo autor.

A figura 42 ilustra a expressão de busca e para responder a quarta questão de competência, que visa verificar as medicações mais utilizadas para o tratamento. Essa expressão de busca está modelada de forma a somente identificar medicações aplicadas a diagnósticos de transtorno depressivo maior (restrição 1 da figura), cuja classe engloba tanto o transtorno depressivo maior recorrente quanto transtorno depressivo de episódio único com início no periparto.

Baseado no resultado desta expressão é possível verificar que Clonazepam e Sertralina foram os fármacos mais utilizados, conforme o esperado pelas distribuições apresentadas na tabela 15 e na tabela 16.

Figura 42: Expressão de busca SPARQL para resposta da questão de competência 4

```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX m: <http://www.unisinos.br/pipca/ontologies/eroutines#>

SELECT ?medication ( COUNT(?person) as ?medicatedPersonCount )
WHERE {
  ?assessment m:hasSociodemographicProfile ?sociodemprof ;
              m:hasDiagnosis ?diagnosis ;
              m:belongToContext ?diagnosisContext .

  ?diagnosis a m:NewDiagnosis ;
              a m:ConfirmedDiagnosis ;
              m:hasDisorder ?disorder ;
              m:hasPrescribedMedication ?medication .

  ?disorder a m:MajorDepression .
}
GROUP BY ?medication ORDER BY DESC(?medicatedPersonCount)

```

Execute

| ?medication | ?medicatedPersonCount |
|---------------------------|-----------------------|
| m:Medication-Clonazepam | 124 |
| m:Medication-Sertraline | 116 |
| m:Medication-Fluoxetine | 83 |
| m:Medication-Escitalopram | 70 |
| m:Medication-Diazepam | 57 |

Fonte: Elaborado pelo autor.

A última questão de competência visa encontrar uma relação entre medicação e remissão nos dados simulados, e para isso foi executado duas expressões de busca SPARQL, uma agrupando por classe e outra por instância de transtorno com objetivo de demonstrar a capacidade da inferência agrupar transtornos similares para construção do perfil epidemiológico.

As expressões de busca estão ilustradas na figura 43, onde se pode verificar a restrição por um diagnóstico confirmado (item 1), que o mesmo transtorno diagnosticado em outra avaliação como em remissão (item 3), que ambos sejam da mesma pessoa (itens 2 e 4). A restrição 5 da expressão ao lado esquerdo da figura é responsável por identificar a classe do transtorno em vez da instância, cujo resultado está apresentado na tabela 17.

Figura 43: Expressões de busca para medicação com maior índice de remissão por transtorno, lado esquerdo a expressão por classe de transtorno, ao lado direito por instância de transtorno

```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX m: <http://www.unisinos.br/pipca/ontologies/eroutines#>

SELECT ?medication ?disorderClass ( COUNT(?person) as ?remissionCount )
WHERE {
  ?assessment m:hasSociodemographicProfile ?sociodemprof ;
              m:hasDiagnosis ?diagnosis ;
              m:belongsToContext ?diagnosisContext .

  ?diagnosis a m:NewDiagnosis ;
             a m:ConfirmedDiagnosis ;
             m:hasDisorder ?disorder ;
             m:hasPrescribedMedication ?medication .

  ?diagnosisContext m:happenedWithPerson ?person .

  ?remissionAssessment m:belongsToContext ?remissionContext ;
                      m:hasDiagnosis ?remissionDiagnosis .

  ?remissionDiagnosis a m:RemissionDiagnosis ;
                     m:hasDisorder ?disorder .

  ?disorder rdf:type ?disorderClass .
  ?disorderClass rdfs:subClassOf m:Disorder .

  ?remissionContext m:happenedWithPerson ?person .
}
GROUP BY ?medication ?disorderClass ORDER BY DESC(?remissionCount)

```

```

PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX m: <http://www.unisinos.br/pipca/ontologies/eroutines#>

SELECT ?medication ?disorder( COUNT(?person) as ?remissionCount )
WHERE {
  ?assessment m:hasSociodemographicProfile ?sociodemprof ;
              m:hasDiagnosis ?diagnosis ;
              m:belongsToContext ?diagnosisContext .

  ?diagnosis a m:NewDiagnosis ;
             a m:ConfirmedDiagnosis ;
             m:hasDisorder ?disorder ;
             m:hasPrescribedMedication ?medication .

  ?diagnosisContext m:happenedWithPerson ?person .

  ?remissionAssessment m:belongsToContext ?remissionContext ;
                      m:hasDiagnosis ?remissionDiagnosis .

  ?remissionDiagnosis a m:RemissionDiagnosis ;
                     m:hasDisorder ?disorder .

  ?remissionContext m:happenedWithPerson ?person .
}
GROUP BY ?medication ?disorder ORDER BY DESC(?remissionCount)

```

Fonte: Elaborado pelo autor.

A tabela 17 apresenta os resultados dessas expressões, onde é possível notar a relação entre as medicações e as classes de transtornos respeitando as distribuições apresentadas na tabela 15 e na tabela 16. Também é possível verificar a capacidade do modelo de inferir a classe do transtorno baseado nas características da instancia, como é o caso da Sertralina na classe Transtorno depressivo maior com 62 casos que corresponde a Sertralina utilizada para o transtorno depressivo maior recorrente e transtorno depressivo maior em episódio único no periparto, com 57 e 5 casos, respectivamente.

Tabela 17: Resultado das expressões de busca da questão de competência 5

| Medicação | Classe de transtorno ou transtorno específico | Casos em remissão |
|--|---|-------------------|
| Resultado da busca por classe de transtorno | | |
| Clonazepam | Transtorno de ansiedade generalizada | 102 |
| Sertralina | Transtorno de ansiedade generalizada | 81 |
| Sertralina | Transtorno depressivo maior | 62 |
| Clonazepam | Transtorno depressivo maior | 62 |
| Fluoxetina | Transtorno de ansiedade generalizada | 57 |
| Escitalopram | Transtorno de ansiedade generalizada | 46 |
| Diazepam | Transtorno de ansiedade generalizada | 38 |
| Fluoxetina | Transtorno depressivo maior | 37 |
| Escitalopram | Transtorno depressivo maior | 36 |

| | | |
|---|--|-----|
| Diazepam | Transtorno depressivo maior | 28 |
| Clonazepam | Transtorno de ansiedade generalizada | 102 |
| Sertralina | Transtorno de ansiedade generalizada | 81 |
| Sertralina | Transtorno depressivo maior | 62 |
| Resultado da busca por transtorno específico | | |
| Clonazepam | Transtorno de ansiedade generalizada | 102 |
| Sertralina | Transtorno de ansiedade generalizada | 81 |
| Clonazepam | Transtorno depressivo maior recorrente | 62 |
| Sertralina | Transtorno depressivo maior recorrente | 57 |
| Fluoxetina | Transtorno de ansiedade generalizada | 57 |
| Escitalopram | Transtorno de ansiedade generalizada | 46 |
| Diazepam | Transtorno de ansiedade generalizada | 38 |
| Fluoxetina | Transtorno depressivo maior recorrente | 35 |
| Escitalopram | Transtorno depressivo maior recorrente | 34 |
| Diazepam | Transtorno depressivo maior recorrente | 28 |
| Sertralina | Transtorno depressivo maior em episódio único no 5 periparto | 5 |
| Fluoxetina | Transtorno depressivo maior em episódio único no 2 periparto | 2 |
| Escitalopram | Transtorno depressivo maior em episódio único no 2 periparto | 2 |

Fonte: Elaborado pelo autor.

5.3.4 Complexidade temporal da inferência

Estudos epidemiológicos tem por objetivo analisar as características de uma população, como grupos baseados em informações sociodemográficas em perfis epidemiológicos, visando descobrir a relação de uma doença ou transtorno com uma característica que indique um risco maior. É possível verificar nos estudos epidemiológicos brasileiros uma massa de dados que varia de dezenas a milhares de indivíduos.

Esta seção apresenta uma avaliação de complexidade temporal da inferência baseada no desempenho do motor de inferência HerMiT utilizando uma extrapolação dos dados simulados e discute as implicações da realização de inferência em ontologias com muitas instâncias.

Para avaliar o motor de inferência foram utilizados subgrupos com indivíduos extrapolados a partir dos dados da simulação apresentados na seção anterior, com os seguintes números de pacientes: (a) 25 pacientes, (b) 50 pacientes, (c) 100 pacientes, (d) 200 pacientes, (e) 400 pacientes, (f) 800 pacientes, (g) 1600 pacientes, (h) 3200 pacientes e (i) 6400 pacientes.

O processamento das inferências em todos os indivíduos foi executada para cada um dos grupos, sendo o procedimento de inferência executado duas vezes e descartados com intuito de garantir alocação de memória e capacidade de processamento para a máquina virtual, e cinco vezes para efetivamente avaliar o tempo necessário para realização das inferências de classes para todos os pacientes, seus contextos, diagnósticos e transtornos.

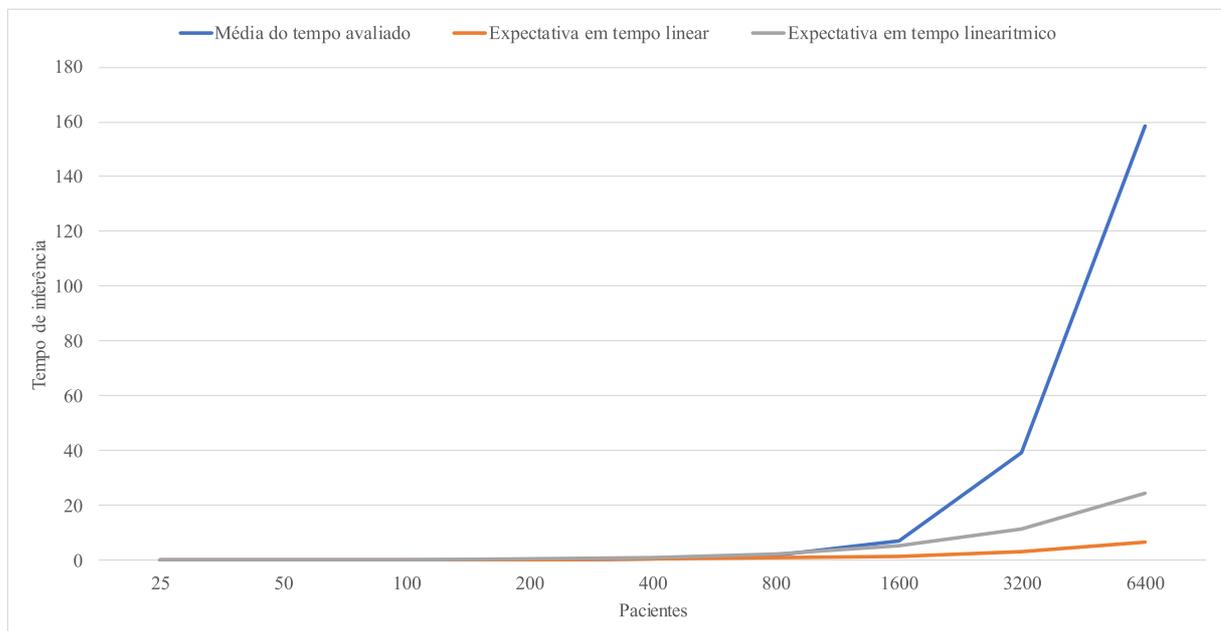
Cada avaliação teve duração mínima de 10 segundos, onde medições adicionais foram realizadas para os grupos em que a inferência levou menos de 10 segundos conforme indicado na tabela 18.

O ambiente foi um sistema operacional Windows 10 Enterprise 1809 64 bits com um processador Intel i5-8350U e 16GB de RAM DDR4-2400, onde o HerMiT 1.3.8 foi avaliado utilizando o *Java Microbenchmark Harness* em uma máquina virtual OpenJDK 13.0.2 de 64 bits e o processo de execução da máquina virtual recebeu a prioridade máxima no sistema operacional para evitar interrupções durante a avaliação.

Todos os dados foram pré-carregados em memória antes do teste de desempenho para evitar que o teste fosse afetado pelo tempo de I/O dos arquivos, que para 6400 pacientes gerou um XML de aproximadamente 20MB.

Os resultados obtidos estão apresentados na tabela 18 e representados graficamente pela figura 44, onde o tempo médio para cada grupo de pacientes representado pela linha azul apresenta um aumento superior às curvas estimadas de tempo linear e linearítico por grupo.

Figura 44: Gráfico de desempenho de inferência



Fonte: Elaborado pelo autor.

Na tabela 18 é possível observar que o tempo de inferência para uma ontologia composta por mais de 800 pacientes supera o crescimento linear e linearítico estimado para o mesmo tempo de inferência, ou seja, a complexidade temporal da inferência é superior à $O(n \log(n))$ para mais de 800 pacientes, porém inferior a $O(n^2)$. Nesta mesma tabela a expectativa de tempo

linear foi calculada como $(\frac{n}{1000})$ e a expectativa de tempo linearitmico foi calculada como $(\frac{n \log(n)}{1000})$ onde n é o número de pacientes na ontologia.

Tabela 18: Resultado da avaliação de desempenho, tempo em segundos por inferência

| Número de pacientes | Número de medições | Tempo de inferência medido | Expectativa em tempo linear | Expectativa em tempo linearitmico |
|----------------------------|---------------------------|-----------------------------------|------------------------------------|--|
| 25 | 1556 | 0.032 ± 0.001 | 0.025 | 0.035 |
| 50 | 1081 | 0.046 ± 0.001 | 0.050 | 0.085 |
| 100 | 539 | 0.093 ± 0.003 | 0.100 | 0.200 |
| 200 | 264 | 0.192 ± 0.007 | 0.200 | 0.460 |
| 400 | 108 | 0.474 ± 0.018 | 0.400 | 1.041 |
| 800 | 29 | 1.89 ± 0.069 | 0.800 | 2.322 |
| 1600 | 10 | 7.052 ± 1.295 | 1.600 | 5.127 |
| 3200 | 5 | 39.064 ± 3.666 | 3.200 | 11.216 |
| 6400 | 5 | 158.538 ± 46.232 | 6.400 | 24.360 |

Fonte: Elaborado pelo autor.

Considerando tanto o aumento do tempo de inferência quanto a possibilidade de realizar a inferência de forma individualizada (por instância) se recomenda para uma implementação produtiva deste modelo a realização das inferências durante a ingestão dos dados no sistema de armazenamento, bem como a execução de inferências de forma assíncrona ao se expandir a ontologia com novas classes para serem inferidas a fim de evitar a necessidade de inferências durante a execução das expressões de busca para construção dos perfis epidemiológicos.

6 CONCLUSÃO

Esta tese propôs um modelo computacional para identificação de rotinas e comparação de padrões de comportamento baseado em histórico de contextos. Tal modelo é composto por princípios e características básicas necessárias para tal comparação: Indicadores, Sensoriamento, Contexto, Histórico de contextos, Comparação, Confirmação, Tratamento e Acompanhamento.

Após apresentar estes princípios básico o modelo propõe uma arquitetura e define um algoritmo de identificação de rotinas baseada em histórico de contextos capaz de lidar com variáveis discretas e contínuas, bem como os passos necessários para computar rotinas em *eigenbehaviors*.

Complementando o algoritmo de identificação de rotinas, o modelo Eigenroutine propõe a identificação de comparação adaptativa de contextos, bem como um algoritmo de cálculo de distância de rotinas.

O modelo computacional foi avaliado com um histórico de contexto utilizando 693 dias de informações capturadas de 55 indivíduos, divididos entre grupos de controle e depressão e validado em termos de: (a) acurácia na classificação de pessoas com distúrbios de comportamento, (b) capacidade de identificação de mudanças na rotina ao longo do tempo e (c) determinação de perfis epidemiológicos após a confirmação de diagnóstico.

Por fim, diagnósticos acompanhados de perfis sociodemográficos de 1066 indivíduos foram simulados baseados em três trabalhos da literatura médica e os resultados de expressões de busca SPARQL utilizando inferências baseadas na ontologia do modelo foram apresentadas, confirmando a capacidade de construir perfis epidemiológicos a partir do modelo proposto, bem como uma análise da complexidade temporal de inferência das instâncias na ontologia proposta.

A principal contribuição deste trabalho é o algoritmo de identificação e comparação de rotinas em histórico de contextos com variáveis contínuas e discretas acompanhado de uma ontologia de histórico de contextos para saúde mental com suporte a construção de perfis epidemiológicos, cujo escopo também pode ser aplicado em um sistema de acompanhamento e tratamento de transtornos neuropsiquiátricos.

O motivo de ser a principal contribuição é devido a combinação única de equações aplicadas a um novo problema na área neuropsiquiátrica, bem como o incremento em forma de formalidade de relação entre conceitos aplicada ao mesmo problema.

Como contribuição secundária este trabalho apresenta um mapeamento sistemático da utilização de computação ubíqua para acompanhamento e tratamento de transtornos neuropsiquiátricos e modelo arquitetural para implementação do Eigenroutine.

6.1 Limitações da tese

É importante ressaltar que a amplitude o trabalho impede o aprofundamento em todas as questões e possibilidades apresentadas, e neste trabalho a maior ameaça a viabilidade e potencial viés é avaliar o trabalho utilizando dados de trabalhos anteriores sem um parecer de um profissional da área para corroborar.

Para mitigar o impacto o modelo incorpora a utilização de biomarcadores avaliados independentemente deste trabalho, e basear o modelo em um dos principais modelos estatísticos para transtornos neuropsiquiátricos (DSM-V).

O segundo potencial de viés na avaliação é a utilização da simulação baseado em perfis epidemiológicos de cenários Brasileiros, que naturalmente apresentam questões sociodemográficas locais e podem influenciar no resultado caso aplicado em outros países.

6.2 Trabalhos futuros

Durante o desenvolvimento e avaliação do modelo foram identificadas as seguintes oportunidades para trabalhos futuros:

- Aplicar o modelo no tratamento simultâneo de diferentes transtornos e avaliar a capacidade do modelo de distinguir diferentes rotinas e diferentes distúrbios de comportamento;
- Comparar diferentes técnicas de modelagem de contexto no Eigenroutines, como, por exemplo, avaliar a performance de classificação quando o *Eigenbehavior* é calculado utilizando indicadores específicos de um transtorno e comparar com a performance quando o mesmo é calculado com indicadores de vários transtornos simultaneamente;
- Avaliar o modelo de identificação de perfis epidemiológicos em larga escala, preferencialmente em diferentes regiões para evitar o viés causado por questões culturais;
- Aplicar o Eigenroutines para identificação de relapsos comparando alterações na rotina de um mesmo indivíduo;
- Aplicar o Eigenroutines em problemas computacionais que requerem identificação e comparação de rotinas mas não estão necessariamente relacionadas ao distúrbio de comportamento.

6.3 Artigos publicados relacionados a Tese

Os seguintes artigos foram publicados relacionados ao tema desta tese:

1. BUTTENBENDER, Paulo C.; MARTINS, Márcio G.; BARBOSA, Jorge L. V. Ubiquitous computing applied to mental health: trends and research focus. In: **Proceedings of the 24th Brazilian Symposium on Multimedia and the Web**. 2018. p. 73-76. DOI: <https://doi.org/10.1145/3243082.3267456>
2. PETRY, Milene M.; BARBOSA, Jorge L.V.; RIGO, Sandro J.; DIAS, Lucas P. S.; BUTTENBENDER, Paulo C. Toward a ubiquitous model to assist the treatment of people with depression. **Universal Access in the Information Society**, p. 1-14, 2019. DOI: <https://doi.org/10.1007/s10209-019-00697-4>
3. BAVARESCO, Rodrigo; BARBOSA, Jorge; VIANNA, Henrique; BUTTENBENDER, Paulo; DIAS, Lucas. Design and evaluation of a context-aware model

based on psychophysiology. **Computer Methods and Programs in Biomedicine**, v. 189, p. 105299, 2020. DOI: <https://doi.org/10.1016/j.cmpb.2019.105299>

REFERÊNCIAS

- ABDULLAH, S. *et al.* **Automatic detection of social rhythms in bipolar disorder.** [S. l.: s. n.]
- AHARONY, Nadav *et al.* The Social fMRI: Measuring, Understanding, and Designing Social Mechanisms in the Real World. **13th International Conference on Ubiquitous Computing (UbiComp 2011)**, [S. l.], p. 445–454, 2011.
- ALSHAMSI, Aamena *et al.* Beyond Contagion: Reality Mining Reveals Complex Patterns of Social Influence. [S. l.], p. 1–59, 2015. Disponível em: <http://arxiv.org/abs/1507.04192>
- ALTMAN, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. **American Statistician**, [S. l.], 1992.
- ARAÚJO, Ivan De Sousa *et al.* Postpartum Depression: Epidemiological Clinical Profile of Patients Attended in a Reference Public Maternity in Salvador-BA. **Revista Brasileira de Ginecologia e Obstetricia**, [S. l.], 2019.
- BAASCH, Davi; TREVISAN, Rafaela Luiza; CRUZ, Roberto Moraes. Epidemiological profile of public servants absent from work due to mental disorders from 2010 to 2013. **Ciencia e Saude Coletiva**, [S. l.], 2017.
- BANOS, Oresti; HERVÁS, Ramón. Ubiquitous computing for health applications. **Journal of Ambient Intelligence and Humanized Computing**, [S. l.], v. 10, n. 6, p. 2091–2093, 2019. Disponível em: <https://doi.org/10.1007/s12652-018-0875-3>
- BARBOSA, Jorge *et al.* TrailCare: An indoor and outdoor Context-aware system to assist wheelchair users. **International Journal of Human Computer Studies**, [S. l.], 2018.
- BARBOSA, Jorge L. V. Ubiquitous computing: Applications and research opportunities. *In*: 2015, **2015 IEEE International Conference on Computational Intelligence and Computing Research (ICIC)**. [S. l.: s. n.]
- BAVARESCO, R. *et al.* Design and evaluation of a context-aware model based on psychophysiology. **Computer Methods and Programs in Biomedicine**, [S. l.], v. 189, 2020.
- BEN-ZEEV, Dror *et al.* Comparing retrospective reports to real-time/real-place mobile assessments in individuals with schizophrenia and a nonclinical comparison group. **Schizophrenia Bulletin**, [S. l.], 2012.
- BERTOLETE, José Manoel; FLEISCHMANN, Alexandra. A global perspective in the epidemiology of suicide. **suicidology**, [S. l.], 2002.
- BLAINE, Bruce. Does depression cause obesity? A meta-analysis of longitudinal

studies of depression and weight control. **Journal of Health Psychology**, [S. l.], 2008.

BONATO, P. Clinical applications of wearable technology. **Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference**, [S. l.], 2009.

BROOKS, K. The context quintet: narrative elements applied to context awareness. **Human Computer Interaction International ...**, [S. l.], 2003. Disponível em: http://xenial.media.mit.edu/~brooks/storybiz/Brooks-context_quintet.pdf. Acesso em: 30 out. 2012.

BURNS, Michelle Nicole *et al.* Harnessing context sensing to develop a mobile intervention for depression. **Journal of Medical Internet Research**, [S. l.], 2011.

BÜTTENBENDER, Paulo C.; BARBOSA, Jorge L. V.; MARTINS, Marcio G. Ubiquitous computing applied to mental health. *In*: 2018, New York, New York, USA. **Proceedings of the 24th Brazilian Symposium on Multimedia and the Web - WebMedia '18**. New York, New York, USA: ACM Press, 2018. p. 73–76. Disponível em: <http://dl.acm.org/citation.cfm?doid=3243082.3267456>

BÜTTENBENDER, Paulo Cesar. **Uma plataforma para computação sensível a contexto baseada em tecnologias web e armazenamento distribuído de ontologias**. 2013. - Universidade do Vale do Rio dos Sinos, [s. l.], 2013. Disponível em: www.repositorio.jesuita.org.br/handle/UNISINOS/4665

COGGON, David; BARKER, David; ROSE, Geoffrey. **Epidemiology for the Uninitiated, 5th Edition**. 5. ed. [S. l.: s. n.].

COHEN, Sheldon; TYRRELL, David A. J.; SMITH, Andrew P. Psychological Stress and Susceptibility to the Common Cold. **New England Journal of Medicine**, [S. l.], 1991.

CORTES, Corinna; VAPNIK, Vladimir. Support-Vector Networks. **Machine Learning**, [S. l.], 1995.

DA ROSA, João H.; BARBOSA, Jorge L. V. V; RIBEIRO, Giovane D. ORACON: An adaptive model for context prediction. **Expert Systems with Applications**, [S. l.], 2016.

DALARMELINA, A. C.; ALMANÇA, A. C. D.; OLIVEIRA-CORTEZ, P. J. Epidemiological Profile of Depression and Anxiety in a City of the South of Minas Gerais. **Journal of Depression and Anxiety**, [S. l.], v. 6, n. 2, 2017.

DANG, M. *et al.* Accompanying depression with FINE-a smartphone-based approach. *In*: 2016, **Studies in health technology and informatics**. [S. l.: s. n.]

DE MONTJOYE, Yves-Alexandre *et al.* The strength of the strongest ties in collaborative problem solving. **Scientific reports**, [S. l.], v. 4, p. 5277, 2014. Disponível em:

<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=4064431&tool=pmcentrez&rendertype=abstract>

- DIAS, Lucas Pfeiffer Salomão. **iAware: Um modelo para Cuidado ubíquo de Pacientes com Transtornos de Ansiedade, Depressão e Estresse utilizando Gamificação e Biodata**. 2018. - Universidade do Vale do Rio dos Sinos, [s. l.], 2018.
- DIAS, Lucas Pfeiffer Salomão *et al.* Development and testing of iAware model for ubiquitous care of patients with symptoms of stress, anxiety and depression. **Computer Methods and Programs in Biomedicine**, [S. l.], 2019.
- EAGLE, Nathan Norfleet. Machine perception and learning of complex social systems. **Media**, [S. l.], p. 136, 2005.
- EAGLE, Nathan; PENTLAND, Alex Sandy. Eigenbehaviors: Identifying structure in routine. **Behavioral Ecology and Sociobiology**, [S. l.], v. 63, n. 7, p. 1057–1066, 2009.
- FAEDDA, Gianni L. *et al.* Actigraph measures discriminate pediatric bipolar disorder from attention-deficit/hyperactivity disorder and typically developing controls. **Journal of Child Psychology and Psychiatry and Allied Disciplines**, [S. l.], 2016.
- FAURHOLT-JEPSEN, Maria *et al.* Daily electronic self-monitoring of subjective and objective symptoms in bipolar disorder—the MONARCA trial protocol (MONitoring, treAtment and pRediCtion of bipolar disorder episodes): a randomised controlled single-blind trial. **BMJ Open**, [S. l.], 2013.
- FAURHOLT-JEPSEN, Maria *et al.* Daily electronic monitoring of subjective and objective measures of illness activity in bipolar disorder using smartphones– the MONARCA II trial protocol: a randomized controlled single-blind parallel-group trial. **BMC Psychiatry**, [S. l.], 2014.
- FAURHOLT-JEPSEN, Maria *et al.* Smartphone data as an electronic biomarker of illness activity in bipolar disorder. **Bipolar Disorders**, [S. l.], v. 17, n. 7, p. 715–718, 2015.
- FERNANDES, Paulo César Barbosa. **An ontology-based system to generate epidemiologic profiles**. 2012. - Universidade Federal do Espírito Santo, [s. l.], 2012.
- FIRTH, Joseph; TOROUS, John; YUNG, Alison R. Ecological momentary assessment and beyond: The rising interest in e-mental health research. **Journal of Psychiatric Research**, [S. l.], 2016.
- FROST, Mads *et al.* Supporting disease insight through data analysis. **Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing - UbiComp '13**, [S. l.], 2013.
- GARCIA-CEJA, Enrique *et al.* Depresjon: A motor activity database of depression

episodes in unipolar and bipolar patients. *In*: 2018, **Proceedings of the 9th ACM Multimedia Systems Conference, MMSys 2018**. : Association for Computing Machinery, Inc, 2018. p. 472–477.

GILES, Jim. Making the Links. **Nature**, [S. l.], v. 488, p. 448–450, 2012. Disponível em: http://www.wateraid.org/documents/plugin_documents/making_the_links.pdf

GITLIN, Michael. Lithium side effects and toxicity: prevalence and management strategies. **International Journal of Bipolar Disorders**, [S. l.], 2016.

GLIMM, Birte *et al.* Hermit: An OWL 2 Reasoner. **Journal of Automated Reasoning**, [S. l.], 2014.

GODBOUT, Jonathan P.; GLASER, Ronald. **Stress-induced immune dysregulation: Implications for wound healing, infectious disease and cancer**. [S. l.: s. n.]

GREEN, M. F. **Cognitive impairment and functional outcome in schizophrenia and bipolar disorder**. [S. l.: s. n.]

GRUBER, Tom. Ontology. *In*: LIU, Ling; ÖZSU, M. Tamer (org.). **Encyclopedia of Database Systems**. [S. l.]: Springer-Verlag, 2009. *E-book*. Disponível em: <http://tomgruber.org/writing/ontology-in-encyclopedia.htm>

HAN, J.; KAMBER, M.; PEI, J. **Data Mining**. 3rd. ed. [S. l.]: Elsevier Inc., 2012.

HASTIE, Trevor *et al.* Multi-class AdaBoost. **Statistics and Its Interface**, [S. l.], 2009.

HELPER, Gilson Augusto *et al.* A model for productivity and soil fertility prediction oriented to ubiquitous agriculture. *In*: 2019, **Proceedings of the 25th Brazillian Symposium on Multimedia and the Web, WebMedia 2019**. [S. l.: s. n.]

HENRY, C. *et al.* Affective instability and impulsivity in borderline personality and bipolar II disorders: similarities and differences. **Journal of psychiatric research**, [S. l.], 1992.

HONG, Jongyi *et al.* Context-aware system for proactive personalized service based on context history. **Expert Systems with Applications**, [S. l.], 2009.

INSEL, Thomas R. *et al.* Research Domain Criteria (RDoC): Toward a new classification framework for research on mental disorders. **Am J Psychiatry**, [S. l.], 2010.

JAIMES, Luis G.; LLOFRIU, Martin; RAIJ, Andrew. PREVENTER, a Selection Mechanism for Just-in-Time Preventive Interventions. **IEEE Transactions on Affective Computing**, [S. l.], 2016.

JIMENEZ-SERRANO, Santiago; TORTAJADA, Salvador; GARCIA-GOMEZ, Juan Miguel. A Mobile Health Application to Predict Postpartum Depression Based on Machine Learning. **Telemedicine journal and e-health : the official journal of the American Telemedicine Association**, [S. l.], 2015.

- JOHNSON, Sheri L.; LEAHY, Robert L. Psychological treatment of bipolar disorder. *In: Psychological treatment of bipolar disorder. [S. l.: s. n.]*.
- KAMDAR, Maulik R.; WU, Michelle J. Prism: a Data-Driven Platform for Monitoring Mental Health. **Pacific Symposium on Biocomputing. Pacific Symposium on Biocomputing**, [S. l.], 2016.
- KERZ, Maximilian *et al.* SleepSight: a wearables-based relapse prevention system for schizophrenia. *In: 2016, Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing Adjunct - UbiComp '16. [S. l.: s. n.]*
- KLOSTERKÖTTER, Joachim *et al.* Diagnosing Schizophrenia in the Initial Prodromal Phase. **Archives of General Psychiatry**, [S. l.], 2001.
- LAURINDO, Maria Vitória; LOPES, Roberlândia Evangelista; ROCHA, Renan Rhonalty. Epidemiological Profile of Elderly with Depressive Disorders in a Municipality of Northeast Brazil. **Brazilian Journal of Health Review**, [S. l.], v. 3, n. 1, 2020.
- LAZER, David *et al.* Life in the network: the coming age of computational social. **Science**, [S. l.], v. 323, n. 5915, p. 721–723, 2009.
- LIDDLE, Peter F. **Disordered mind and brain: the neural basis of mental symptoms**. 1st. ed. [S. l.]: Royal College of Psychiatrists, 2001.
- LOBBESTAEL, Jill; LEURGANS, Maartje; ARNTZ, Arnoud. Inter-rater reliability of the Structured Clinical Interview for DSM-IV Axis I Disorders (SCID I) and Axis II Disorders (SCID II). **Clinical psychology & psychotherapy**, [S. l.], 2010.
- MADAN, Anmol *et al.* Social sensing for epidemiological behavior change. *In: 2010, Proceedings of the 12th ACM international conference on Ubiquitous computing - UbiComp '10. [S. l.: s. n.]*
- MANTANI, Akio *et al.* Smartphone cognitive behavioral therapy as an adjunct to pharmacotherapy for refractory depression: Randomized controlled trial. **Journal of Medical Internet Research**, [S. l.], 2017.
- MATTHEWS, M. *et al.* Development and Evaluation of a Smartphone-Based Measure of Social Rhythms for Bipolar Disorder. **Assessment**, [S. l.], 2016.
- MAYORA, Oscar *et al.* Personal Health Systems for Bipolar Disorder. *In: 2013, Proceedings of the 3rd International Workshop on Pervasive Computing Paradigms for Mental Health (MindCare). International ICST Conference on Pervasive Computing Technologies for Healthcare (Pervasive Health), 3rd, May 5, San Servolo Island, Venice, Italy. [S. l.: s. n.]*
- MOFFITT, Terrie E. *et al.* Depression and generalized anxiety disorder: Cumulative and sequential comorbidity in a birth cohort followed prospectively to age 32 years. **Archives of General Psychiatry**, [S. l.], 2007.

- MOHR, David *et al.* MedLink: A Mobile Intervention to Address Failure Points in the Treatment of Depression in General Medicine. *In: 2015, Proceedings of the 9th International Conference on Pervasive Computing Technologies for Healthcare.* [S. l.: s. n.]
- MOLINA, Mariane Ricardo Acosta Lopez *et al.* Prevalence of depression in users of primary care settings. **Revista de Psiquiatria Clinica**, [S. l.], 2012.
- MONTGOMERY, S. A.; ASBERG, M. A new depression scale designed to be sensitive to change. **British Journal of Psychiatry**, [S. l.], 1979.
- O'BRIEN, J. T. *et al.* A study of wrist-worn activity measurement as a potential real-world biomarker for late-life depression. **Psychological Medicine**, [S. l.], 2016.
- OSIPOV, Maxim. **Towards automated symptoms assessment in mental health.** 2016. - University of Oxford, [s. l.], 2016.
- PALMIUS, N. *et al.* A multi-sensor monitoring system for objective mental health management in resource constrained environments. *In: 2014, Appropriate Healthcare Technologies for Low Resource Settings (AHT 2014).* [S. l.: s. n.]
- PEJOVIC, Veljko; MUSOLESI, Mirco. Anticipatory Mobile Computing: A Survey of the State of the Art and Research Challenges. **ACM Comput. Surv**, [S. l.], v. 47, n. 47, 2015. Disponível em: <http://dx.doi.org/10.1145/2693843>
- PETRY, Milene M. *et al.* Hígia: Um modelo para cuidado ubíquo de pessoas com depressão. *In: 2016, XII Simpósio Brasileiro de Sistemas de Informação (SBSI).* [S. l.: s. n.] p. 433–440.
- PETRY, Milene Martini *et al.* Toward a ubiquitous model to assist the treatment of people with depression. **Universal Access in the Information Society**, [S. l.], 2019.
- QUINLAN, J. R. Induction of decision trees. **Machine Learning**, [S. l.], v. 1, n. 1, p. 81–106, 1986.
- RASMUSSEN, Carl Edward; WILLIAMS, Christopher K. I. **Gaussian Processes for Machine Learning.** [S. l.: s. n.].
- REICHE, E. M. V; NUNES, S. O. V; MORIMOTO, Helena Kaminami. **Stress, depression, the immune system, and cancer.** [S. l.: s. n.]
- ROJAS, Isolde-Gina *et al.* Stress-Induced Susceptibility to Bacterial Infection During Cutaneous Wound Healing. **Brain, Behavior, and Immunity**, [S. l.], 2002.
- ROSA, João H. *et al.* A Multi-Temporal Context-aware System for Competences Management. **International Journal of Artificial Intelligence in Education**, [S. l.], 2015.
- RUMMEL-KLUGE, C.; KOMOSSA, K. Head-to-head comparisons of metabolic side effects of second generation antipsychotics in the treatment of schizophrenia: a

- systematic review and meta-analysis. **Schizophrenia ...**, [S. l.], 2010.
- RUSH, AJ; FIRST, MB; BLACKER, D. **Handbook of psychiatric measures, second edition**. [S. l.: s. n.].
- SATYANARAYANAN, M. Pervasive computing: vision and challenges. **Ieee Personal Communications**, [S. l.], v. 8, n. 4, p. 10–17, 2001. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=943998>
- SEZER, Omer Berat; DOGDU, Erdogan; OZBAYOGLU, Ahmet Murat. **Context-Aware Computing, Learning, and Big Data in Internet of Things: A Survey**. [S. l.: s. n.]
- SHADBOLT, N.; HALL, W.; BERNERS-LEE, T. The semantic web revisited. **Intelligent Systems, IEEE**, [S. l.], v. 21, n. 3, p. 96–101, 2006. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1637364>. Acesso em: 31 out. 2012.
- SHEDLER, J.; MAYMAN, M.; MANIS, M. The Illusion of Mental-Health. **American Psychologist**, [S. l.], 1993.
- STOPCZYNSKI, Arkadiusz *et al.* Measuring large-scale social networks with high resolution. **PLoS ONE**, [S. l.], v. 9, n. 4, 2014.
- TUDORACHE, Tania *et al.* Ontology development for the masses: Creating ICD-11 in WebProtégé. *In*: 2010, **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**. [S. l.: s. n.]
- TUDORACHE, Tania *et al.* Using semantic web in ICD-11: Three years down the road. *In*: 2013, **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**. [S. l.: s. n.]
- USTÜN, T. B. The global burden of mental disorders. **American Journal of Public Health**, [S. l.], 1999.
- VALENZA, Gaetano *et al.* Mood recognition in bipolar patients through the PSYCHE platform: Preliminary evaluations and perspectives. **Artificial Intelligence in Medicine**, [S. l.], 2013.
- VAN MELLE, J. P. *et al.* Prognostic association of depression following myocardial infarction with mortality and cardiovascular events: a meta-analysis. **Psychosomatic medicine: Journal of the American Psychosomatic Society**, [S. l.], 2004.
- VIGO, Daniel; THORNICROFT, Graham; ATUN, Rifat. Estimating the true global burden of mental illness. **The Lancet Psychiatry**, [S. l.], 2016.
- W3C. **Resource Description Framework (RDF): Concepts and Abstract Syntax**. [S. l.], 2004a. Disponível em: <http://www.w3.org/TR/2004/REC-rdf-concepts->

20040210/. Acesso em: 20 jan. 2013.

- W3C. **OWL Web Ontology Language Guide**. [s. l.], 2004b. Disponível em: <http://www.w3.org/TR/owl-guide/>. Acesso em: 30 out. 2012.
- W3C. **OWL 2: Web Ontology Language Document Overview**. [s. l.], 2009. Disponível em: <http://www.w3.org/TR/owl2-overview/>. Acesso em: 30 out. 2012.
- WAGNER, Andr ; BARBOSA, Jorge Luis Vict ria; BARBOSA, D bora Nice Ferrari. A model for profile management applied to ubiquitous learning environments. **Expert Systems with Applications**, [S. l.], 2014.
- WANT, Roy. An Introduction to Ubiquitous Computing. In: KRUMM, John (org.). **Ubiquitous Computing Fundamentals**. 1. ed. [S. l.: s. n.]. p. 1–36.
- WATANABE, Norio *et al.* Adding smartphone-based cognitive-behavior therapy to pharmacotherapy for major depression (FLATT project): study protocol for a randomized controlled trial. **Trials**, [S. l.], 2015.
- WEISER, Mark. The Computer for the 21 st Century. **Scientific American**, [S. l.], v. 3, n. 3, p. 94–104, 1991. Disponível em: <http://portal.acm.org/citation.cfm?id=329124.329126>
- WEISSMAN, M. M. Advances in psychiatric epidemiology: Rates and risks for major depression. **American Journal of Public Health**, [S. l.], 1987.
- WHO EUROPE. **Data and Statistics: Prevalence of Mental Disorders**. [s. l.], 2014.
- WIKIMEDIA. **Van Gogh - Trauernder alter Mann**. [s. l.], 2020. Disponível em: https://commons.wikimedia.org/wiki/File:Van_Gogh_-_Trauernder_alter_Mann.jpeg. Acesso em: 26 jul. 2017.
- WORLD HEALTH ORGANIZATION. **WHO Mental Health AtlasWorld Health Organization**. [S. l.: s. n.].
- WORLD HEALTH ORGANIZATION. Global burden of mental disorders and the need for a comprehensive, coordinated response from health and social sectors at the country level. **130Th Session**, [S. l.], 2012.
- WORLD HEALTH ORGANIZATION. Depression and other common mental disorders: global health estimates. **World Health Organization**, [S. l.], 2017.